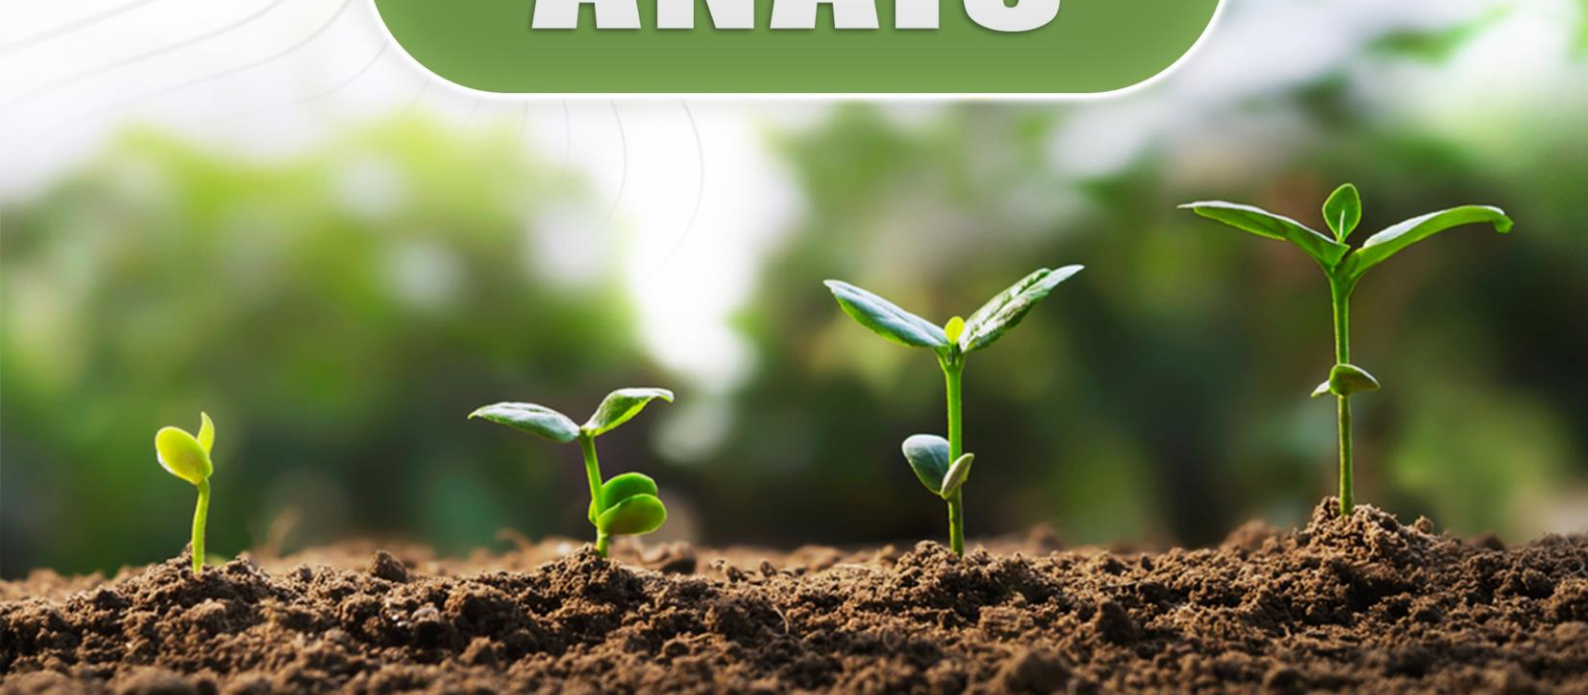
ConBAP 2024

CONGRESSO BRASILEIRO DE AGRICULTURA DE PRECISÃO E DIGITAL

RIBEIRÃO PRETO - SP | 25 A 27 DE NOVEMBRO

ANAIS



Promoção

AsBraAP

Patrocínio Diamante

JACTO Next

Patrocínio Ouro

FENDT

IBRA megalab

Stara Evolução Constante

Patrocínio Prata

WEED-IT precision spraying

SAVEFARM PULVERIZAÇÃO SELETIVA

Geodata

WEIGHTECH AGRO

Apoio

CNPq

CAPES

ISBN E DADOS DE PUBLICAÇÃO

X Congresso Brasileiro de Agricultura de Precisão e Digital
25 a 27 de novembro de 2024 | Ribeirão Preto – SP

Edição técnica
Christian Bredemeier e Leandro Maria Gimenez

Todos os resumos neste livro foram reproduzidos de cópias fornecidas pelos autores e o conteúdo dos textos é de exclusiva responsabilidade dos mesmos. A organização do referente evento não se responsabiliza por consequências decorrentes do uso de quaisquer dados, afirmações e/ou opiniões inexatas ou que conduzam a erros publicados neste livro de trabalhos. É de inteira responsabilidade dos autores o registro dos trabalhos nos conselhos de ética, de pesquisa ou equivalentes de área.

Copyright © 2024 – Todos os direitos reservados
Todos os direitos reservados. Nenhuma parte desta obra pode ser reproduzida, arquivada ou transmitida, em qualquer forma ou por qualquer meio, sem permissão escrita da Associação Brasileira de Agricultura de Precisão e Digital.



APRESENTAÇÃO

A Edição 2024 do ConBAP foi realizada em Ribeirão Preto - SP, no Multiplan Hall (Ribeirão Shopping), de 25 a 27 de novembro de 2024. A décima edição do evento foi uma realização da Associação Brasileira de Agricultura de Precisão e Digital (AsBraAP), que vem se consolidando como um ambiente plural de conexão entre o campo e as novas tecnologias.

A agricultura de precisão é uma estratégia de gestão que reúne, processa e analisa dados temporais, individuais e espaciais e os combina com outras informações para apoiar as decisões de gerenciamento de acordo com a variabilidade estimada para melhorar a eficiência no uso de recursos, produtividade, qualidade, rentabilidade e sustentabilidade da produção agropecuária.

Durante o evento, estiveram reunidos produtores, empresários, professores, pesquisadores, empresas do setor produtivo, revendas agrícolas, instituições de ensino e pesquisa e consultores, entre outros. O congresso é uma oportunidade para fortalecer o networking, conhecer colaboradores para pesquisas, atividades profissionais e extensionistas.

O ConBAP 2024 buscou ser um espaço de debate científico entre pesquisadores da área, a fim de promover o diálogo entre temáticas que englobam a agricultura de precisão. O evento, realizado de forma bienal, reuniu mais de 600 participantes envolvidos no amplo leque da agricultura de Precisão e digital (AP&D).

COMISSÕES DO EVENTO

Comissão Organizadora

Bruno Lucio
Diretor de Relacionamento Empresarial da AsBraAP

Christian Bredemeier
Vice-diretor Científico da AsBraAP

Fábio Torres
Secretário da AsBraAP

Leandro Maria Gimenez
Diretor Científico da AsBraAP

Pedro Palatnik
Diretor de Relacionamento Governamental da AsBraAP

Marcio Albuquerque
Vice-presidente da AsBraAP

Marcos Ferraz
Presidente da AsBraAP

Comissão Científica

Alberto Carlos de Campos Bernardi
Empresa Brasileira de Pesquisa Agropecuária (Embrapa)

André Luis Vian
Universidade Federal do Rio Grande do Sul (UFRGS)

Christian Bredemeier
Universidade Federal do Rio Grande do Sul (UFRGS)

Leandro Maria Gimenez
Universidade de São Paulo (ESALQ - USP)

Lucas de Paula Corrêdo
Universidade Federal de Viçosa (UFV)

Lucas Rios do Amaral
Universidade Estadual de Campinas (Unicamp)

Luís Henrique Bassoi
Empresa Brasileira de Pesquisa Agropecuária (Embrapa)

Samuel de Assis Silva
Universidade Federal do Espírito Santo (UFES)

REVISORES *AD HOC*

Alberto Carlos de Campos Bernardi - EMBRAPA
Alessandro Samuel-Rosa - UTFPR
André Freitas Colaço – ESALQ/USP
André Luis Vian - UFRGS
André Luiz de Freitas Coelho- UFV
Antônio Luis Santi - UFSM
Celia Regina Grego - EMBRAPA
Christian Bredemeier - UFRGS
Daniel Marçal de Queiroz - UFV
Domingos Sárvio Magalhães Valente - UFV
Eduardo Leonel Bottega - UFSM
Fabio Henrique Rojo Baio - UFMS
Gabriel Araújo e Silva Ferraz - UFLA
Guilherme Martineli Sanches - USP
Gustavo Di Chiacchio Faulin - FATEC/SP
Henrique Oldoni - UNICAMP
José Paulo Molin - USP
José Vitor Salvi – Fatec Pompeia
Leandro Maria Gimenez - USP
Lucas de Paula Corrêdo - UFV
Lucas Rios do Amaral - UNICAMP
Luciano Gebler - EMBRAPA
Lúcio de Paula Amaral - UFSM
Luis Henrique Bassoi - EMBRAPA
Miguel Angel Uribe Opazo - UNIOESTE
Rafael Vieira de Sousa - USP
Renato Maravalhas de Carvalho Barros – Fatec Ourinhos
Ricardo Sobjak - UTFPR
Ronaldo Pereira de Oliveira - EMBRAPA
Ronilson de Souza Santos - UFPA
Rouverson Pereira da Silva - UNESP
Rubens Andre Tabile - USP
Rubens Augusto Camargo Lamparelli - UNICAMP
Samuel de Assis Silva - UFES
Tatiana Fernanda Canata - UNESP
Thiago Libório Romanelli - USP
Tiago Rodrigues Tavares - USP

PROGRAMAÇÃO

Programação 25/11/2024

Horário	Atividade	Local
11:30 - 13:30	Recepção e Credenciamento	
13:30 - 14:15	**Solenidade de abertura do ConBAP 2024:** Análise das dez edições do ConBAP. *Palestrante: Marcos Nascimbem Ferraz - AsBraAP*MC: Pedro Palatnik - Diretor de Relações Governamentais da AsBraAP	Auditório Principal
14:15 - 15:00	**Plenária:** Evolução e futuro da agricultura de precisão no mundoMediador: Marcos Ferraz	Auditório Principal
14:15 - 15:00	**Palestra: O futuro da agricultura de precisão no mundo** *Palestrante: Dr. John Fulton - Ohio State University, Presidente da International Society of Precision Agriculture*	Auditório Principal
15:00 - 15:30	**Perguntas e Debate**	
15:30 - 15:35	**Lançamento de livro:** Rede AP da Embrapa	
15:35 - 16:00	**Coffee break e Visita aos estandes:** Informações sobre o livro no estande da AsBraAP	
16:00 - 18:00	**Plenária:** A interface entre Agricultura de Precisão e Agricultura regenerativaMediador: Rodrigo Trevisan	Auditório Principal
16:00 - 16:45	**Palestra: Contribuição da Agricultura de Precisão para a sustentabilidade agrícola** *Palestrante: Prof. Telmo Amado - Universidade Federal de Santa Maria (UFSM)*	Auditório Principal
16:45 - 17:20	**Palestra: Tecnologias aplicadas para alta produtividade, sustentabilidade e lucratividade na produção de grãos** *Palestrante: Pedro Basso - Eng. Agrônomo - Sementes com Vigor*	Auditório Principal
17:20 - 18:00	**Perguntas e Debate**	
18:00 - 18:30	Visita aos estandes	
19:00 - 21:30	Coquetel de Abertura do ConBAP 2024	

Programação 26/11/2024

Horário	Atividade	Local
08:30 - 10:00	**Plenária:** Avanços nas recomendações de adubação no contexto da Agricultura de Precisão. Mediador: Lucas Amaral	Auditório Principal
08:30 - 09:05	**Palestra: Otimizando recomendações agronômicas de nitrogênio em cana-de-açúcar usando tecnologias de avaliação da variabilidade espacial de solos e plantas** *Palestrante: Dr. Guilherme Sanches - CCarbon/USP*	Auditório Principal
09:05 - 09:40	**Palestra: Avanços na aplicação de nitrogênio em taxa variável e a integração de conhecimentos na Agricultura de Precisão** *Palestrante: Dr. Leonardo Mendes Bastos - Instituto de Agricultura de Precisão Integrada, University of Georgia (EUA)*	Auditório Principal
09:40 - 10:00	**Perguntas e Debate**	
10:00 - 10:05	**Homenagens póstumas:** Maikol Carvalho e Isabel Regina Flores Carneiro	Auditório Principal
10:30 - 12:15	**Apresentação de trabalhos científicos (Apresentações orais):** *Atividades simultâneas	Auditório Principal
10:30 - 17:00	Sala de Mercado	
14:00 - 15:35	**Plenária:** Experimentação on-farm: desafios e oportunidades. Mediador: Luís Henrique Bassoi	Auditório Principal
14:00 - 14:35	**Palestra: Experimentação On-farm** *Palestrante: Dr. Fabricio Povh - Fundação ABC*	Auditório Principal
14:35 - 15:10	**Palestra: Exemplos reais e desafios da experimentação on-farm** *Palestrante: M.Sc. Fernando Scaramuzza - Instituto Nacional de Tecnología Agropecuária, INTA Manfredi, Argentina*	Auditório Principal
15:10 - 15:30	**Perguntas e Debate**	
16:00 - 17:00	Apresentação de trabalhos Científicos (Sessão de pôsteres)	
17:00 - 18:10	**Painel:** Visão de usuários: Agricultura digital na prática. Mediadora: Jessica Costalonga	Auditório Principal
17:00 - 17:20	**Visão 1** *Palestrante: Fábio Taira - GCAP - Fazenda São Caetano (MT)*	Auditório Principal
17:20 - 17:40	**Visão 2** *Palestrante: Rafael Gonçalves Peluco - Usina São Martinho*	Auditório Principal
18:20 - 20:00	Reunião dos associados AsBraAP	

Programação 27/11/2024

Horário	Atividade	Local
08:30 - 10:00	**Plenária:** A transformação digital na agricultura. Mediador: Marcio Albuquerque	Auditório Principal
08:30 - 09:05	**Palestra: Quem será o produtor de grãos do futuro?** *Palestrante: André Dobashi - Presidente da Comissão Nacional de Cereais, Fibras e Oleaginosas da CNA*	Auditório Principal
09:05 - 09:40	**Palestra: A meteorologia como ferramenta de agricultura de precisão e digital** *Palestrante: Felipe Pilau - Esalq/USP e Weather Service*	Auditório Principal
09:40 - 10:00	**Perguntas e Debate**	
10:00 - 10:30	Coffee break e Visita aos estandes	
10:30 - 11:45	**Plenária:** Avanços e qualidade nas aplicações de produtos fitossanitários com drones. Mediador: Christian Bredemeier	Auditório Principal
10:30 - 11:10	**Palestra: Aplicação com drones em cana-de-açúcar** *Palestrante: José Carlos Monteiro - Grupo Tereos*	Auditório Principal
11:10 - 11:40	**Palestra: Pesquisando a pulverização com drones em soja** *Palestrante: Dr. Rafael Moreira Soares - EMBRAPA Soja*	Auditório Principal
11:40 - 11:55	**Perguntas e Debate**	
11:55 - 13:00	Posse da nova diretoria da AsBraAP (Biênio 2024-2026) Encerramento do ConBAP 2024	Auditório Principal

LIVRO DE RESUMOS

Sumário

1. Agronomia/Manejo..... 16

UTILIZAÇÃO DE ÍNDICES ESPECTRAIS RGB NO MONITORAMENTO DE CULTIVO DE MILHO PARA SILAGEM..... 17

ANAIDE CAROLANE DA SILVA SANTOS [1]; MARCELO COELHO FURTADO [2]; GABRIEL FERREIRA DE OLIVEIRA [3]; MARIA EDUARDA GOMES [2]; MIGUEL JULIO MACHADO GUIMARÃES [4]..... 17

PRODUTIVIDADE DA CANA-DE-AÇÚCAR EM FUNÇÃO DA APLICAÇÃO DE DIFERENTES DOSES DE NITROGÊNIO, COM BASE NAS VARIAÇÕES DA CONDUTIVIDADE ELÉTRICA APARENTE (CE_A) DO SOLO..... 23

Guilherme Martineli Sanches [1]; Hugo Miranda Faria [4]; Almir Salvador Neto [5]; Rafael Otto [2]; José Eduardo Corá [3]..... 23

VARIABILIDADE ESPACIAL DA RESISTÊNCIA DO SOLO À PENETRAÇÃO..... 36

Jorge Wilson Cortez [1]; Diandra Pinto Della Flora [2]; Dario Alexandre Schwambach [3]..... 36

É VIÁVEL DEMARCAR ZONAS DE CARBONO ORGÂNICO DO SOLO COM BASE EM DADOS DIGITAIS? 42

LUIZ GUSTAVO DE GÓES STERLE [1]; RICARDO CANAL FILHO [2]; EUDOCIO RAFAEL OTÁVIO DA SILVA [2]; MARCELO CHAN FU WEI [2]; JOSÉ PAULO MOLIN [3]..... 42

UM ESTUDO DE CASO SOBRE EXPERIMENTAÇÃO ON FARM PARA AVALIAÇÃO DE POPULAÇÕES DE PLANTAS DE SOJA COM USO DOS RECURSOS DISPONÍVEIS NA FAZENDA..... 50

MARCELLO RODRIGUES ALVES FRANCHI [1]; ISRAEL MOLINA CYRINEU [2]; FABIO KAGAMI TAIRA [3]; LUCAS HUNHOFF [4]; LEANDRO MARIA GIMENEZ [5]..... 50

ANÁLISE ESPACIAL DA PRODUTIVIDADE DE CENOURA IRRIGADA CORRELACIONADA COM ATRIBUTOS QUÍMICOS DO SOLO..... 58

Gloria Milena Rojas Plazas [1]; Erli Pinto dos Santos [1]; Job Teixeira de Oliveira [2]; Rubens Alves de Oliveira [3]... 58

CORRELAÇÃO ENTRE ÍNDICES ESPECTRAIS RGB E A PRODUTIVIDADE DE GRÃOS DE MILHO..... 66

GABRIEL FERREIRA DE OLIVEIRA [1]; ANA BEATRIZ DANTAS LOPES [2]; MARCELO COELHO FURTADO [3]; ANAIDE CAROLANE DA SILVA SANTOS [4]; MIGUEL JULIO MACHADO GUIMARÃES [5]..... 66

VARIABILIDADE ESPACIAL DE ATRIBUTOS QUÍMICOS DO SOLO NA PRODUÇÃO DE PASTAGEM EM SISTEMA DE INTEGRAÇÃO-PECUÁRIO-FLORESTA..... 72

DIEGO JORGE DA SILVA [1]; ROBERTO BARROS AGUIAR [1]; RODRIGO DE SOUZA PINHEIRO [1]; CLEMESON CARDOSO VALE [2]; MIGUEL JULIO MACHADO GUIMARÃES [3]..... 72

UTILIZANDO IMAGENS RGB E ALGORITMOS DE CLASSIFICAÇÃO PARA DIFERENCIAR SOLOS VISANDO VITICULTURA DE PRECISÃO..... 78

Adão Felipe dos Santos [1]; Octavio Pereira Costa [2]; Matheus Ardigueri [2]; Wender Henrique Barbosa da Silva [2]; Pedro Maranha Peche [1]..... 78

QUALIDADE DE SEMEADURA DE ARROZ PRÉ-GERMINADO COM USO DE DRONE..... 85

Lidiane Bortoli [1]; Gilvan Moises Bertollo [2]; Matheus Da Silva [1]; Antonio Luis Santi [2]; Stela Kulczynski [2]..... 85

ANÁLISE DA OCORRÊNCIA DO EXCESSO DE VELOCIDADE DE UM PENETRÔMETRO EM UMA ÁREA DE ARRANQUIO DE CAFÉ POR REGRESSÃO LOGÍSTICA..... 89

Rosalra Maria Alves de Morais [1]; Gabriel Araújo e Silva Ferraz [2]; Amara Lana de Abreu [3]; Franck Morais de Oliveira [4]; Aldir Carpes Marques Filho [5]..... 89

RELAÇÃO DE ÍNDICES ESPECTRAIS DE VEGETAÇÃO COM ATRIBUTOS EDÁFICOS EM ÁREA DE PASTAGEM COM MANEJO ROTACIONADO..... 94

JOAO RICARDO FAVAN [1]; RENATA BRUNA DOS SANTOS COSCOLIN FAVAN [1]; JOAO VITOR IENCO BONACINA [2]; JOAO PEDRO IENCO BONACINA [2]; LUIS HENRIQUE SERAFIM DA SILVA [2] *94*

VARIABILIDADE ESPACIAL DO SOLO EM VINHEDO: CONTRIBUIÇÕES DA PEDOLOGIA PARA AGRICULTURA DE PRECISÃO 105

DANIEL ALEXANDRE HEBERLE [1]; CAIO BUSTAMI ANDRADE [1]; GUSTAVO EDUARDO PEREIRA [1]; FELIPE DAMIN [1]; ALEXANDRE TEN CATEN [2] *105*

VARIABILIDADE ESPACIAL DA PRODUTIVIDADE DE MILHO PARA SILAGEM POR DIFERENTES MODELOS DE SEMIVARIOGRAMA 114

ANAIDE CAROLANE DA SILVA SANTOS [1]; RICHARDSON SOARES DE SOUZA MELO [2]; Marcelo Coelho Furtado [3]; GABRIEL FERREIRA DE OLIVEIRA [4]; MIGUEL JULIO MACHADO GUIMARAES [2] *114*

USO DE MAPAS DE DIAGNÓSTICO PARA O ACOMPANHAMENTO DA CONCENTRAÇÃO FOLIAR DE POTÁSSIO NA CULTURA DA SOJA 120

Aline Lampert Dutra [1]; André Müllich [2]; Luciano Zucuni Pes [3]; Ivan Carlos Maldaner [3]; Marcelo Silveira de Farias [3] *120*

ANÁLISE DA VARIABILIDADE ESPACIAL E TEMPORAL DE ATRIBUTOS QUÍMICOS DO SOLO EM ÁREA DE PRODUÇÃO AGRÍCOLA DO COLÉGIO POLITÉCNICO DA UFSM 127

André Müllich [1]; Luiz Felipe Silveira Pavão [1]; Luciano Zucuni Pes [2]; Ivan Carlos Maldaner [2]; Marcelo Silveira de Farias [2] *127*

PRODUTIVIDADE DE CAFÉ BENEFICIADO E A RELAÇÃO COM A MATURAÇÃO DOS FRUTOS OBTIDA A PARTIR DO USO DE IMAGENS 136

GUILHERME PERUZZI CÂNDIDO [1]; SANDRO MANUEL CARMELINO HURTADO [2]; ARTHUR ALVES LEMOS [1]; VITÓRIA MARIA ALVES NUNES [1]; MARIELLE RODRIGUES DUTRA [3] *136*

ÍNDICE NDVI E A SUA CORRELAÇÃO COM A PRODUTIVIDADE DE CAFÉ 141

Múcio Fernando Rodrigues Carneiro Filho [1]; Sandro Carmelindo Hurtado [2]; Wanessa Gonçalves Siquieroli [1]; Felipe Henrique Leandro [1]; Barbara Caetano [1] *141*

2. Aplicação Localizada..... 145

GERAÇÃO DE MAPAS PARA APLICAÇÃO LOCALIZADA DE HERBICIDA UTILIZANDO IMAGENS AÉREAS 146

RONALDO SACOMANI [1]; THIAGO LIBÓRIO ROMANELLI [2]; JÉSSICA DE LUCENA MARINHO [3] *146*

CARACTERIZAÇÃO DA PULVERIZAÇÃO DE DRONES CLASSE III E II EM VINHEDOS COM DOIS SISTEMAS DE CONDUÇÃO 152

Lillian Espindola Müller [1]; Fabio Rossi Cavalcanti [2] *152*

MODELO DE ALERTA DE DOENÇA ENTREGA O INSTANTE E O GEORREFERENCIAMENTO PARA APLICAÇÃO PONTUAL DE FUNGICIDA 157

Fabio Rossi Cavalcanti [1]; Lillian Espindola Müller [2] *157*

VARIABILIDADE ESPACIAL DA ÁGUA DISPONÍVEL E DA CONDUTIVIDADE ELÉTRICA APARENTE NO SOLO PARA DEFINIÇÃO DE ZONAS DE MANEJO DE IRRIGAÇÃO 161

André Müllich [1]; Juliano Dalcin Martins [3]; Luciano Zucuni Pes [2]; Ivan Carlos Maldaner [2]; Marcelo Silveira de Farias [2] *161*

AVALIAÇÃO DO DESEMPENHO DE MODELO *DEEP LEARNING* PARA O RECONHECIMENTO DE PLANTAS DANINHAS NA CULTURA DA SOJA E DO MILHO 169

Estéfani Sulzbach [1]; Ismael Scheeren [3]; Inácio Barbosa [1]; Aldo Merotto Jr [2]; Catarine Markus [2] *169*

DESEMPENHO DE VARIANTES DA YOLOV8 PARA DETECÇÃO DE PLANTAS DANINHAS EM TEMPO REAL NA CULTURA DA SOJA 179

Estéfani Sulzbach [1]; Ismael Scheeren [3]; Manuel Veras [4]; Paula Sinigaglia Angonese [1]; Catarine Markus [2] *179*

3. Economia..... 186

OBTENÇÃO DE ANÁLISES SOCIOECONÔMICAS COM A INTRODUÇÃO DE SÉRIES TEMPORAIS DE ORTOIMAGENS: UMA PROPOSIÇÃO COM BASE NA AGRICULTURA DE PRECISÃO. 187

Helena Fantin Gebler [1] *187*

DETERMINANTES DA ADOÇÃO DE TECNOLOGIAS DE PRECISÃO NA BOVINOCULTURA: UMA REVISÃO SISTEMÁTICA DA LITERATURA 190

Leticia Caroline da Silva David [1]; Marcelo José Carrer [2]; Marcela de Mello Brandão Vinholis [3]; Andrea Lago da Silva [2]; Hildo Meirelles de Souza Filho [2] *190*

VARIAÇÃO DO CUSTO NA SEMEADURA DE SOJA EM FUNÇÃO DO USO DE ZONAS DE MANEJO 201

FELIPE CARNACINI [1]; ANDREY DE OLIVEIRA RIBEIRO LIMA [2]; MURILO APARECIDO VOLTARELLI [3]; CARLA SEGATTO STRINI PAIXÃO [4] *201*

FATORES QUE DIFERENCIAM OS ADOTANTES DE TECNOLOGIAS DIGITAIS EM CONFINAMENTOS DE BOVINOS DE CORTE NO BRASIL 206

GUSTAVO DA SILVA GONÇALVES [1]; LETÍCIA CAROLINE DA SILVA DAVID [1]; MARCELO JOSÉ CARRER [2]; MARCELA DE MELLO BRANDÃO VINHOLIS [3]; HILDO MEIRELLES DE SOUZA FILHO [2] *206*

ESPACIALIZAÇÃO DO PREJUÍZO DAS FALHAS NA FILEIRA DE CANA-DE-AÇÚCAR 213

Eudocio Rafael Otavio da Silva [1]; Ricardo Canal Filho [1]; Marcelo Chan Fu Wei [1]; José Paulo Molin [2] *213*

4. Eletrônica e transformação digital 226

USO DE EQUIPAMENTOS DE BAIXO CUSTO NO DESENVOLVIMENTO DE FERRAMENTAS PARA AGRICULTURA DIGITAL 227

JOÃO MARCELO DOS SANTOS SOARES [1]; JOEL CARNEIRO DA CUNHA JUNIOR [1]; SIMAS SOUZA SANTANA [1]; AMÉLIA LAÍSY DO NASCIMENTO [2]; EMANOEL DI TARSO DOS SANTOS SOUSA [2] *227*

GEOFERT - SOLUÇÃO DIGITAL PARA GESTÃO E CONFORMIDADE NA DESTINAÇÃO DOS DEJETOS DE SUÍNOS EM SANTA CATARINA 232

GEORDANO DALMÉDICO [1]; CLAUDIO ROCHA DE MIRANDA [2] *232*

DESEMPENHO DO PACOTE DE PLANEJAMENTO DE TRAJETÓRIAS FIELDS2COVER EM TALHÕES IRREGULARES E IDENTIFICAÇÃO DE POSSÍVEIS MELHORIAS 237

Enzo Fabricio Casciello [1]; José Paulo Molin [2] *237*

DETECÇÃO DE VIROSES NO MAMOEIRO: UMA ABORDAGEM COM AUTOENCODERS 246

GABRIEL ANTONIO DALAPICULA SERAFINI [3]; DIOGO NOGARA NUNES [2]; JOÃO MARCELO VIEIRA ALVES FILHO [1]; BEATRIZ CORREIA DE ALBUQUERQUE [1]; LUCAS DE PAULA CORRÊDO [4] *246*

5. Sensoriamento e amostragem 253

IDENTIFICAÇÃO DE ÁREAS DE FRUTÍFERAS NA REGIÃO DO SÃO FRANCISCO PERNAMBUCANO COM USO DE SENSORIAMENTO REMOTO 254

Marta Laura de Souza Alexandre [1]; Elisiane Alba [2]; Henrique de Souza Gomes [3] *254*

MONITORAMENTO DA PALMA FORRAGEIRA COM SENSOR RGB A BORDO DE VEÍCULOS NÃO TRIPULADOS 260

Henrique de Souza Gomes [1]; Alan Cesar Bezerra [2]; Marta Laura de Souza Alexandre [3] *260*

MONITORAMENTO DA VARIABILIDADE ESPACIAL DA PRODUTIVIDADE DE POMARES DE CITROS BASEADA EM SENSORES ÓPTICOS E INTELIGÊNCIA ARTIFICIAL 272

PEDRO AUGUSTO MARAZZO DE SOUSA [2]; JOÃO MARCELO VIEIRA ALVES FILHO [1]; PAULO SOUZA RIBEIRO [2]; MATEUS PEREIRA GONZATTO [4]; LUCAS DE PAULA CORRÊDO [4] *272*

DETECÇÃO DO ATAQUE DO BICUDO-DA-CANA (COLEOPTERA: CURCULIONIDAE) VIA SENSORIAMENTO REMOTO ORBITAL 280

João Rafael Silva Soares [1]; Gabriela Franchini [1]; Juliana Lívia Vieira [2]; Vinicius Cesarin [2]; Antonio Maria Garcia Tommaselli [3]; Nilton Nobuhiro Imai [3]; Odair Aparecido Fernandes [1] *280*

ÍNDICES DE VEGETAÇÃO COMO MÉTODOS DE DETECÇÃO E PREDIÇÃO DE DANOS PARA FERRUGEM DA FOLHA NA CULTURA DO TRIGO 287

YURI GUERREIRO RAMOS [1]; MARCELO GIOVANETTI CANTERI [2]; JORGE BENIGNO [3] *287*

SENSORIAMENTO REMOTO AÉREO E INTELIGÊNCIA ARTIFICIAL PARA A CLASSIFICAÇÃO DE PLANTAS DANINHAS EM SILVICULTURA 293

Samuel de Assis Silva [1]; Amanda Teixeira Moreira Capacia [3]; Caique Carvalho Medauar [2] *293*

ESTABILIDADE TEMPORAL DE MODELOS COM BASE EM XRF PARA PREDIÇÃO DE MAGNÉSIO EXTRAÍVEL E CTC EM SOLOS TROPICAIS 299

MARCOS MANTELLI RAGAGNIN [1]; GABRIEL TOLEDO MARQUES [1]; TIAGO RODRIGUES TAVARES [2]; HUDSON WALLACE PEREIRA DE CARVALHO [4]; JOSÉ PAULO MOLIN [3] *299*

MAPEAMENTO DA TEXTURA DO SOLO A PARTIR DE SENSORES DE CONDUTIVIDADE ELÉTRICA (CEA) E SUSCETIBILIDADE MAGNÉTICA (SM) 308

João Vítor Fiolo Pozzuto [1]; Lucas Rios do Amaral [2] *308*

PLATAFORMAS DE AQUISIÇÃO DE DADOS ALTIMÉTRICOS PARA DEMARCAÇÃO DE CURVAS DE NÍVEL EM ARROZ IRRIGADO 319

Charles Nunes da Silva [1]; Érique Almeida Conce Maciel [2]; Chaiane Guerra da Conceição [3]; Lanes Beatriz Acosta Jaques [3]; Vinícius dos Santos Cunha [3] *319*

MODELOS LOCAIS DE SENSORES XRF PARA PREDIÇÃO DE NUTRIENTES DISPONÍVEIS POSSUEM ESTABILIDADE TEMPORAL? 335

Gabriel Toledo Marques [1]; Tiago Rodrigues Tavares [3]; Marcos Mantelli Ragagnin [1]; Jose Paulo Molin [2]; Hudson W P de Carvalho [4] *335*

DESENVOLVIMENTO DE SISTEMA WEB PARA MONITORAMENTO DA OCORRÊNCIA DE CIGARRINHA-DO-MILHO (*DALBULUS MAIDIS*) NO ESTADO PARANÁ 343

Anderson de Toledo [1]; Ricardo Theis Geraldi [2]; Daniel Prado de Campos [3] *343*

USO DE CÂMERAS TÉRMICAS NA DETECÇÃO PRECOCE DE *MELOIDOGYNE EXIGUA* EM CAFEZAIS: UM ESTUDO NA REGIÃO SUL DE MINAS GERAIS 352

Luana Mendes dos Santos [1]; Felipe Augusto Fernandes [2]; Daniele de Brum [3]; Marco Antonio Zanella [4]; Patrícia Ferreira Ponciano Ferraz [5]; Gabriel Araújo e Silva Ferraz [5] *352*

DESENVOLVIMENTO DE PLATAFORMA MULTISENSOR PORTÁTIL PARA CARACTERIZAÇÃO DE VARIABILIDADE ESPACIAL DO SOLO 356

Andre Luiz de Freitas Coelho [1]; Daniel Marçal de Queiroz [1]; Eduardo Leonel Bottega [2]; Emanoel Di Tarso dos Santos Sousa [3]; Marcelo Marques Costa [4] *356*

PREDIÇÃO DE PRODUTIVIDADE DA CANA-DE-AÇÚCAR A PARTIR DE IMAGENS SAR E MULTIESPECTRAIS EM ALTA RESOLUÇÃO ESPACIAL 365

David Lopes Lima [1,3]; José Paulo Molin [2]; Ricardo Canal Filho [3]; Eudocio Rafael Otavio da Silva [3] *365*

DESENVOLVIMENTO DE PLATAFORMA ROBÓTICA COM NAVEGAÇÃO AUTÔNOMA 375

Jamil de Almeida Baltazar [1]; Andre Luiz de Freitas Coelho [2]; Domingos Sárvio Magalhães Valente [2]; Flora Maria de Melo Villar [2] *375*

DETECÇÃO SEMIAUTOMATIZADA DE PLANTAS DE MANGUEIRA CV. TOMMY ATRAVÉS DA DETERMINAÇÃO DO MODELO DIGITAL DE ALTURA 383

GABRIEL FERREIRA DE OLIVEIRA [1]; VICTOR FELIPE CARVALHO DEVESA [2]; ANAIDE CAROLANE DA SILVA SANTOS [3]; JULIANE RAFAELE ALVES BARROS [4]; MIGUEL JULIO MACHADO GUIMARAES [5] *383*

BANDAS MULTIESPECTRAIS SIMULADAS NA CARACTERIZAÇÃO E DISCRIMINAÇÃO DE TRATAMENTOS NUTRICIONAIS EM *EUCALYPTUS SALIGNA* 389

Sally Deborah Pereira da Silva [3]; Lúcio de Paula Amaral [1]; Jocimar Caiafa Milagre [3]; Roberta Aparecida Fantinel [2]; Luciano Zucuni Pes [5] *389*

MAPEAMENTO DA PRODUTIVIDADE UTILIZANDO IMAGENS DE SATÉLITE, PRODUÇÃO DA LAVOURA E FUNÇÃO DENSIDADE DE PROBABILIDADE 402

Ricardo Canal Filho [1]; Marcelo Chan Fu Wei [1]; Eudocio Rafael Otavio da Silva [1]; José Paulo Molin [2] *402*

MONITORAMENTO DE PLANTIOS DE EUCALIPTO COM IMAGENS DE SATÉLITE 412

NORTON BORGES JUNIOR [1,2]; RODRIGO SOUZA BARNECHE [4]; TIAGO RAFAEL DOS SANTOS [3] *412*

POTENCIAL DE SENSOR LIDAR EM DISPOSITIVOS IOS NA MENSURAÇÃO FLORESTAL 416

Bruna Roque Mazzaro [5]; Lúcio de Paula Amaral [1]; Sally Deborah Pereira da Silva [3]; Liane de Souza Weber [2]; Regiane Aparecida Ferreira [4] *416*

OTIMIZAÇÃO DO MÉTODO DE ANÁLISE DE SOLO VIA XRF: AVALIAÇÃO DE CENÁRIOS COM DIFERENTES TEMPOS DE ANÁLISE E REPLICATAS 427

GABRIEL VILLELA BEDUM [1]; MATEUS SILVA GELAIN [1]; TIAGO RODRIGUES TAVARES [2]; HUDSON WALLACE PEREIRA DE CARVALHO [3]; JOSÉ PAULO MOLIN [4] *427*

MAPEAMENTO DE PRODUTIVIDADE DE CANA-DE-AÇÚCAR POR MEIO DE SENSOR VOLUMÉTRICO 436

Julio César Masnello [1]; Filipe de Oliveira Moreira [1]; Ricardo Canal Filho [2]; Eudocio Rafael Otavio da Silva [2]; José Paulo Molin [3] *436*

USO DE APRENDIZADO DE MÁQUINA PARA AVALIAR EFEITOS CAUSADOS POR UMIDADE NA ESPECTROSCOPIA DO SOLO 447

Gabriel Movio Nalin [1]; Ricardo Canal Filho [2]; José Paulo Molin [3] *447*

MICROVARIABILIDADE TEMPORAL DA PRECIPITAÇÃO NO CERRADO DO MATO GROSSO: UMA ABORDAGEM COM DADOS CHIRPS 457

Renan Francisco Rimoldi Tavanti [1]; João Guilherme Faccin [2]; Lucas Felix [3] *457*

DETECÇÃO PRECOCE DE ATAQUE DE NEMATOIDE POR TERMOGRAFIA INFRAVERMELHA EM CULTURA DE ALGODÃO 464

LETÍCIA PIAZENTIN DANTAS [1]; BIANCA BATISTA BARRETO [3]; OTÁVIO RODRIGUES DE PAULA [1]; JOÃO VICTOR SILVA VIANA [1]; DÉBORA,M. B. P. MILORI [2] *464*

PRODUTIVIDADE DA CULTURA DA SOJA E OS ÍNDICES DE VEGETAÇÃO 470

Luiz Gustavo Kern [1]; Marcelo Silveira de Farias [2]; José Cardoso sobrinho [3]; Luciano Zucuni Pes [4]; Ivan Carlos Maldaner [5] *470*

A IMPORTÂNCIA DA SUBAMOSTRAGEM NO MAPEAMENTO DOS ATRIBUTOS DO SOLO 480

Pedro Rodolfo Zolin [1]; Euriana Maria Guimarães [2]; Zigomar Menezes de Souza [3]; Maurício Roberto Cherubin [4]; Lucas Rios do Amaral [5] *480*

EFEITO DO ÂNGULO DA CAMERA EMBARCADA EM DRONE NA COLETA DE DADOS ESPECTRAIS E PREDIÇÃO DE BIOMASSA NA CULTURA DO MILHO 488

Bárbara da Silva Nogueira [1]; Ana Laura Pinto Mucillo [1]; Ana Julia Teixeira Soares [1]; Charleston dos Santos Lima [1]; Christian Bredemeier [2] *488*

AMOSTRAGEM MÍNIMA EM ZONAS DE MANEJO PARA CÁLCULO DA MÉDIA DOS ATRIBUTOS QUÍMICOS FÓSFORO E POTÁSSIO DO SOLO 493

LÍDIA DE OLIVEIRA BAHIA [1]; AMÉLIA LAISY DO NASCIMENTO [2]; EMANOEL DI TARSO DOS SANTOS SOUSA [2]; MARCO ANTONIO ZANELLA [2]; DANIEL MARÇAL DE QUEIROZ [3] *493*

SENSORIAMENTO DE VIBRAÇÃO DE ABELHAS SEM FERRÃO: UM ESTUDO EXLORATÓRIO 504

FELIPE JUCÁ DOS SANTOS [1]; Isac Gabriel Abrahão Bomfim [2]; Marcelo Casimiro Cavalcante [3]; Alexandre Augusto da Penha Coelho [4]; Danielo Gonçalves Gomes [4] *504*

DEFINIÇÃO DE UNIDADES DE GESTÃO DIFERENCIADAS PARA A VITIVINICULTURA 514

GABRIEL ROCHA DE SOUZA [1]; JÚLIA FACCIN FAÉ [2]; ANTÔNIO LUÍS SANTI [3]; GILMAR ARDUINO BETTIO MARODIN [4]; ANDRÉ LUIS VIAN [5] *514*

ESPECTROSCOPIA DE INFRAVERMELHO PRÓXIMO PARA ESTIMATIVA DO TEOR DE NITROGÊNIO EM PLANTAS E GRÃOS DAS CULTURAS DE ARROZ, TRIGO, MILHO E SOJA 523

MÁRCIO GABRIEL MOTKE WRUBLESKI [1]; DIEGO LIMA LUCCHESI [2]; GABRIELA NAIBO [3]; TALES TIECHER [4]; ANDRÉ LUIS VIAN [5] *523*

INCLUSÃO DE ÍNDICES DE VEGETAÇÃO SAR NA PREDIÇÃO DE PRODUTIVIDADE DA SOJA 532

ISABELLA ALVES DA CUNHA [1]; DERLEI DIAS MELO [1]; GUSTAVO MACEDO DE MELO BAPTISTA [3]; LUCAS RIOS DO AMARAL [2] *532*

GERAÇÃO DE NUVENS DE PONTOS MULTIESPECTRAIS POR FOTOGRAMETRIA À CURTA DISTÂNCIA 541

Beatriz Coêlho Silva [1]; Antonio Maria Garcia Tommaselli [2] *541*

DELIMITAÇÃO DE ZONAS DE AMOSTRAGEM DE SOLO E DETERMINAÇÃO DA QUANTIDADE NECESSÁRIA DE SUBAMOSTRAS PARA CARACTERIZAR ATRIBUTOS DE INTERESSE AGRONÔMICO 547

Derlei Dias Melo [1]; Isabella Alves da Cunha [1]; Thiago Luis Brasco [2]; Lucas Rios do Amaral [3] *547*

DANOS POR GEADA EM CAFEEIROS DE DIFERENTES IDADES UMA AVALIAÇÃO COM AERONAVE REMOTAMENTE PILOTADA 558

GISLAYNE FARIAS VALENTE [1]; GABRIEL ARAUJO E SILVA FERRAZ [2]; FELIPE SCHWERZ [3]; RAFAEL DE OLIVEIRA FARIA [4]; MICHEL MARTINS ARAÚJO SILVA [5] *558*

ACOMPANHAMENTO DO DESENVOLVIMENTO DE EUCALIPTO POR SENSORIAMENTO ORBITAL .. 564

Gabriel Ferraz Toledo [1]; Marcelo Chan Fu WEI [2]; José Paulo Molin [3] *564*

ESTIMATIVA DO APORTE DE CARBONO PELA CULTURA DO TRIGO POR MEIO DO ÍNDICE DE VEGETAÇÃO POR DIFERENÇA NORMALIZADA 570

Thauhana Cássia Gasparotto Kuhn [1]; Alexandre Augusto Panisson [2]; Christian Bredemeier [3]; João Leonardo Fernandes Pires [4]; André Luis Vian [5] *570*

AVALIAÇÃO TEMPORAL DE LAVOURA DE ALGODÃO PELO ÍNDICE DE VEGETAÇÃO POR DIFERENÇA NORMALIZADA (NDVI) 578

ALEXANDRE A, PANISSON [1]; ANNA ELISA P. GATELLI [2]; GABRIEL A. ENGEL [2]; TERESA ENDERLE [2] *578*

IMAGEM DE FLUORESCÊNCIA NA DETECÇÃO PRECOCE DE ESTRESSE BIÓTICO NO ALGODÃO 585

OTAVIO RODRIGUES DE PAULA [1]; BIANCA BATISTA BARRETO [2]; LETÍCIA PIAZENTIN DANTAS [1]; JOÃO VICTOR SILVA VIANA [1]; DÉBORA MARCONDES BASTOS MILORI [3] *585*

MAPEAMENTO DA ALTURA DE CAFEEIROS POR MEIO DO SENSOR LIDAR EMBARCADO EM AERONAVE REMOTAMENTE PILOTADA EM LAVOURA ATINGIDA POR GEADA 591

AMARA LANA DE ABREU [1]; GABRIEL ARAÚJO E SILVA FERRAZ [2]; ROSALRA MARIA ALVES DE MORAIS [1]; ARTHUR CORREA DE NORONHA [1]; RAFAEL DE OLIVEIRA FARIA [2] *591*

DIAGNÓSTICO DE MURCHAS VASCULARES DO FEIJOEIRO COMUM COM SENSOR HIPERESPECTRAL 595

ANDRESSA DE SOUZA ALMEIDA [1]; JUSTINO JOSÉ DIAS NETO [2]; WILLIAM RAFAEL RIBEIRO [2]; LAURA CRISTINA DA SILVA ALMEIDA [3]; LETÍCIA DANIELLA MARTINS PARREIRA [3]; RENATA PIRES BATISTA [3]; MÔNICA HITOMI OKURA [4]; ALAERSON MAIA GERALDINE [5]; TAVVS MICAEL ALVES [5]; MURILLO LOBO JUNIOR [6]; RÔMULO MOREIRA SILVA [2] *595*

CORRELAÇÃO ENTRE ÍNDICES DE VEGETAÇÃO SUBORBITAL E PROXIMAL COM O ÍNDICE RELATIVO DO TEOR FOLIAR DE CLOROFILA EM VIDEIRA 'SYRAH' 599

ANDERSON DE JESUS PEREIRA [1]; ISRAEL DE OLIVIERA JUNIOR [2]; LÚCIO ANDRÉ DE CASTRO JORGE [3]; LUIS HENRIQUE BASSOI [4] *599*

FILTRAGEM DE MAPAS DE PRODUTIVIDADE PARA CRIAÇÃO DE MODELOS DE PREDIÇÃO POR SENSORIAMENTO REMOTO 605

Leonardo Correa Oliveira [1]; Cauê Henrique dos Santos [1]; João Vítor Fiolo Pozzuto [2]; Isabella Alves da Cunha [2]; Lucas Rios do Amaral [3] *605*

FENOTIPAGEM DE ALTO RENDIMENTO PARA ESTIMATIVA DE BIOMASSA DE TRIGO PARA PASTEJO USANDO VEÍCULO AÉREO NÃO TRIPULADO E MACHINE LEARNING 610

Luiza Rathke [1]; Charleston dos Santos Lima [3]; Diego Maciel Trevisan [4]; Ernandes Manfroi [5]; Christian Bredemeier [2] *610*

PREDIÇÃO DE CARBONO ORGÂNICO DO SOLO UTILIZANDO BIBLIOTECAS ESPECTRAIS DE SENSORES XRF E VIS-NIR: UMA ANÁLISE COMPARATIVA DO DESEMPENHO INDIVIDUAL E COMBINADO DOS SENSORES 616

Tiago Rodrigues Tavares [1]; Marcos Mantelli Ragagnin [2]; Budiman Minasny [5]; Hudson Wallace Pereira de Carvalho [4]; José Lavres [3] *616*

AVALIAÇÃO DE UM IMPLEMENTO PARA MENSURAÇÃO DE CONDUTIVIDADE ELETRICA APARENTE DO SOLO UTILIZANDO INSTRUMENTAÇÃO COM BASE EM CORRENTE CONTÍNUA 626

SAMARA CRISTINA ROSA [1]; EDIVAN HENRIQUE DE ANDRADE PERES [2]; RODRIGO SINAIDI ZANDONADI [3] *626*

TRANSPARÊNCIA E SELEÇÃO DE BANDAS ESPECTRAIS PARA A MODELAGEM DE CARBONO ORGÂNICO E NITROGÊNIO DO SOLO POR SENSORIAMENTO PRÓXIMO 633

Erli Pinto dos Santos [1]; Renata Ranielly Pedroza Cruz [2]; Gloria Milena Rojas Plazas [3]; Uemeson José dos Santos [4]; Michel Castro Moreira [5] *633*

MAPEAMENTO DE ATRIBUTOS DE SOLO COM SENSOR INTELIGENTE 639

BEATRIZ REGINA DA SILVA SANTOS [3]; MARIA ELOYSE GONÇALVES LUIZ [3]; AMÉLIA LAÍSY DO NASCIMENTO [1]; DANIEL MARÇAL DE QUEIROZ [2]; EMANOEL DI TARSO DOS SANTOS SOUSA [1] *639*

VARIABILIDADE ESPACIAL/INTERANUAL DO QUOCIENTE FOTOTERMAL NO SUL DO BRASIL E SEU IMPACTO NO POTENCIAL DE RENDIMENTO DO TRIGO 643

Gilberto Rocca da Cunha [3]; Grazieli Rodigheri [1]; Aldemir Pasinato [3]; João Leonardo Fernandes Pires [3]; Jordano Bortoncello [2] *643*

PREDIÇÃO DE PRODUTIVIDADE DA BATATA INGLESA A PARTIR DE SENSORIAMENTO REMOTO ORBITAL 648

Samira Luns Hatum de Almeida [1]; Jarlyson Brunno Costa Souza [2]; Bruno Ripa Baptista [3]; Vinicius dos Santos Carreira [2]; Rouverson Pereira da Silva [4] *648*

IDENTIFICAÇÃO DE ZONAS DE MANEJO PARA A APLICAÇÃO DE REGULADOR DE CRESCIMENTO NA CULTURA DO ALGODÃO UTILIZANDO BIOMASS PROXY 653

LAYANE CARMEM ARRUDA DA ROCHA [1]; MAYKON RODRIGO GOMES DE BARROS [3]; MICHEL CASTRO MOREIRA [2] *653*

DIFERENCIAÇÃO DE CULTIVARES DE BATATA A PARTIR DE TÉCNICAS DE SENSORIAMENTO REMOTO E APRENDIZADO DE MÁQUINAS 658

Bruno Ripa Baptista [1]; Airton Andrade da Silva [2]; Samira Luns Hatum de Almeida [3]; Vinicius dos Santos Carreira [4]; Rouverson Pereira da Silva [5] *658*

PREDIÇÃO DO NITROGÊNIO FOLIAR DA CANA-DE-AÇUCAR UTILIZANDO DADOS ESPECTRAIS DE SATÉLITE: APLICAÇÃO DE REGRESSÃO POR EXTREME GRADIENT BOOSTING 664

ROMÁRIO PORTO DE OLIVEIRA [1]; THIAGO CAIO MOURA OLIVEIRA [1]; CINTIA CARMEN DE FARIA MELO [1]; RENATO DE MELLO PRADO [2]; TATIANA FERNANDA CANATA [2]; CARLOS EDUARDO ANGELI FURLANI [2] *664*

6. Técnicas de análise de dados 670

DETECÇÃO DE PRAGAS DA AVICULTURA USANDO REDES NEURAIS CONVOLUCIONAIS 671

Geordano Dalmédico [1] *671*

ANÁLISE DA VARIABILIDADE NA SEMEADURA E SEUS EFEITOS NA PRODUTIVIDADE DE MILHO NO SUL DE MINAS 677

WENDER HENRIQUE BATISTA DA SILVA [1]; ALEXANDRE DOS SANTOS [2]; FRANKLIN DANIEL INÁCIO [1]; ADÃO FELIPE DOS SANTOS [2]; EDUARDO HENRIQUE ARANTES TERRA [1] *677*

MAPEAMENTO DE ATRIBUTOS DO SOLO POR MEIO DA KRIGAGEM COM DERIVA EXTERNA E INFORMAÇÕES AUXILIARES PROVINDAS DA AGRICULTURA DE PRECISÃO 682

Júlia de Paula Tavares do Nascimento [1]; Laura Delgado Bejarano [2]; Lucas Rios do Amaral [3] *682*

DELINEAMENTO DE ZONAS DE MANEJO E AVALIAÇÃO DE EXPERIMENTAÇÃO ON-FARM PARA DIFERENTES POPULAÇÕES DE SEMENTES UTILIZANDO SENSORIAMENTO REMOTO E PROXIMAL NA CULTURA DO ALGODÃO 688

Eduardo Antonio Speranza [1]; Ivani de Oliveira Negrão Lopes [2]; Carlos Manoel Pedro Vaz [3]; Julio Cezar Franchini dos Santos [2]; João de Mendonça Naime [3]; Ricardo Yassushi Inamasu [3]; Sérgio das Chagas [4] *688*

APLICABILIDADE DE DADOS ESPACIALIZADOS OBSERVACIONAIS NA CANA-DE-AÇÚCAR 697

MARCELO CHAN FU WEI [1]; EUDOCIO RAFAEL OTAVIO DA SILVA [1]; RICARDO CANAL FILHO [1]; JOSÉ PAULO MOLIN [2] *697*

REVISITANDO O TEMA DOS ERROS EM DADOS OBTIDOS POR MONITORES DE PRODUTIVIDADE DE MILHO E SOJA 707

LUIZ GUSTAVO DE GÓES STERLE [1]; MARCELO CAMPONEZ DO BRASIL CARDINALI [1,3]; LEONARDO VEDOVATO GIMENEZ [1]; VINICIUS CAMPANA BENASSI [1]; JOSÉ PAULO MOLIN [2] *707*

APRENDIZADO DE MÁQUINAS NA PREDIÇÃO DO ÍNDICE DE ÁREA FOLIAR EM LAVOURA CAFEEIRA NA REGIÃO DE SANTO ANTÔNIO DO AMPARO-MG 718

AMARA LANA DE ABREU [1]; GABRIEL ARAÚJO E SILVA FERRAZ [2]; ROSALRA MARIA ALVES DE MORAIS [1]; FRANCK MORAIS DE OLIVEIRA [1]; ARTHUR CORREA DE NORONHA [1] *718*

ADULANÇO 4.0: UMA ATUALIZAÇÃO EM USABILIDADE PARA ANÁLISE DE DISTRIBUIDORES TRANSVERSAIS 723

Mateus Silva Gelain [1]; Gabriel Villela Bedum [1]; José Paulo Molin [2] *723*

ANÁLISE DE ÁREAS INSTÁVEIS E ESTÁVEIS EM SÉRIES TEMPORAIS MENSAIS DE PRECIPITAÇÃO PARA CULTIVO DA SOJA, MATO GROSSO - MT 732

Fabrícia Conceição Menez Mota [1,2]; Maria Carolina. da S. Andrea [1]; Rodrigo de S. Oliveira [1,3]; Edilson Freire R. Junior [1]; Victor Gabriel S, Barbosa [1] *732*

INLA, UMA ALTERNATIVA A O USO DA KRIGAGEM NA ANÁLISE DE SOLO 739

Lucas Monteiro Bianchi [1,2]; Fabrícia Conceição Menez Mota [2]; Cristiano Ferreira de Oliveira [2]; Rafael Carlos dos Santos [2]; Caio Marchiorato de Gouveia [2] *739*

PREDIÇÃO DA PRODUTIVIDADE DA BANANEIRA UTILIZANDO VARIÁVEIS DE SOLO, PLANTA E ÍNDICES DE VEGETAÇÃO EM URABÁ, COLÔMBIA. 747

Laura Delgado Bejarano [1]; Darío Castañeda Sanchez [2]; Juan José Pérez Zapata [3]; Sebastián Zapata Henao [4]; Lucas Rios do Amaral [5] *747*

ZONEAMENTO DE VINHEDO PARA MANEJO DE NUTRIÇÃO E COLHEITA UTILIZANDO APRENDIZADO DE MÁQUINA 753

CAIO BUSTANI ANDRADE [1]; DANIEL ALEXANDRE HEBERLE [2]; MATHEUS SOUSA SILVA [3]; CRISTIAN SOLDI [5]; ALEXANDRE TEN CATEN [5] *753*

SOFTWARE PARA ESTIMATIVA DE PRODUTIVIDADE DA CANA-DE-AÇÚCAR BASEADO EM IMAGENS DE SENSORIAMENTO REMOTO 762

Caio Simplicio Arantes [1]; Eduardo Antonio Speranza [2]; Joao Francisco Goncalves Antunes [3]; Luiz Antonio Falaguasta Barbosa [2]; Geraldo Magela de Almeida Cançado [3] *762*

ESTIMATIVA DA PRODUTIVIDADE NÃO OBTIDA DEVIDO ÀS FALHAS EM CANAVIAIS 769

Murilo Oliveira Cardoso [1]; Eudocio Rafael Otavio Da Silva [2]; Ricardo Canal Filho [3]; José Paulo Molin [4] *769*

TÉCNICAS DE MACHINE LEARNING E SENSORIAMENTO REMOTO NA PREDIÇÃO DE ALTURA DE PLANTAS EM ÁREAS COMERCIAIS DE ALGODÃO 776

Maria Carolina da Silva Andrea [1]; Cristiano Ferreira de Oliveira [1]; Lucas Monteiro Bianchi [1]; Rafael Carlos dos Santos [1,2]; Caio Marchiorato de Gouveia [1,3] *776*

IDENTIFICANDO PADRÕES DE DADOS DE PRODUTIVIDADE E DE FALHAS EM CANAVIAIS COM TÉCNICA DE AGRUPAMENTO 787

Gabriel Fogaça [1]; Eudocio Rafael Otavio da Silva [2]; José Paulo Molin [3] *787*

DESEMPENHO DE MÉTODOS DE FILTRAGEM PARA DADOS DE PRODUTIVIDADE EM CANAVIAIS UTILIZANDO DADOS DISCREPANTES ARTIFICIAIS 794

Yuri de Lacerda Barbosa [1]; Eudocio Rafael Otavio da Silva [2]; Marcelo Chan Fu Wei [3]; José Paulo Molin [4] *794*

INTEGRANDO DADOS ESPACIAIS E MACHINE LEARNING PARA PREDIZER A MATURAÇÃO DE AMENDOIM 804

Octávio Pereira da Costa [1]; Thiago Orlando Costa Barboza [1]; Wender Henrique Batista da Silva [1]; Franklin Daniel Inácio [1]; Adão Felipe dos Santos [2] *804*

METODOLOGIA RELM-BLUP APLICADA A SELEÇÃO DE ATRIBUTOS ESPECTRAIS E PREDIÇÃO DE VARIÁVEIS NA CULTURA DO MILHO 811

Charleston dos Santos Lima [1]; Luiza Rathke [2]; Ivan Ricardo Carvalho [3]; Christian Bredemeier [4] *811*

IMPACTO DO MÉTODO DE INTERPOLAÇÃO EM SITUAÇÃO DE LIMITAÇÃO AMOSTRAL NOS MAPAS DE PRESCRIÇÃO DE FERTILIZANTES 825

Lucas Rios do Amaral [1]; Derlei Dias Melo [2]; Laura Delgado Bejarano [2]; Thiago Luis Brasco [3]; Henrique Oldoni [4] *825*

VARIABILIDADE DE INDICADORES DE QUALIDADE NA COLHEITA MECANIZADA DE SORGO 836

KRISTHIAN BENDER JAEGER [1]; ROUVERSON PEREIRA DA SILVA [2]; VINÍCIUS DOS SANTOS CARREIRA [3]; BRENO DOS SANTOS SILVA [4] *836*

GERAÇÃO DE DADOS SINTÉTICOS PARA USO EM VISÃO COMPUTACIONAL E PULVERIZAÇÃO AGRÍCOLA 843

JOEL CARNEIRO DA CUNHA JUNIOR [1]; AMÉLIA LAISY DO NASCIMENTO [2]; JOÃO MARCELO DOS SANTOS SOARES [1]; JOSELY CARLA FERREIRA MENDES [1]; VICTOR BATISTA RODRIGUES [1] *843*

FILTRAGEM AUTOMÁTICA DE DADOS DE PRODUTIVIDADE DE CANA-DE-AÇÚCAR 853
Eudocio Rafael Otavio da Silva [1]; Marcelo Chan Fu Wei [1]; Ricardo Canal Filho [1]; José Paulo Molin [2] *853*
TRATAMENTO DE DADOS DE MONITOR DE COLHEITA DE CANA-DE-AÇÚCAR PARA MAPEAMENTO DA PRODUTIVIDADE 864
Bruna da Silva Brito Ribeiro [1]; Rodrigo Greggio de Freitas [2]; Lucas Rios do Amaral [3] *864*
VISÃO COMPUTACIONAL E APRENDIZADO DE MÁQUINA PARA A QUANTIFICAÇÃO DE FERRUGEM (HEMILEIA VASTATRIX) NA CULTURA DO CAFEEIRO 871
Marisa Silveira Almeida Renaud Faulin [1]; Lucas de Brito Silva [2]; Álvaro Leandro Cavalcante Carneiro [2]; Gustavo Di Chiacchio Faulin [1] *871*
INFLUÊNCIA DA "CAUDA DO PATAMAR" NO AJUSTE SEMIVARIOGRÁFICO E NAS ESTIMATIVAS DO ÍNDICE SMP POR KRIGAGEM ORDINÁRIA PONTUAL 878
Frederico Ravazi de Castro [1]; Gilberto Galle [1]; Leonardo Mello Foletto [1]; Lucas Cagliari Grando [1]; Lúcio De Paula Amaral [2]; Luise Jardim Pedó [1]; Maria Eduarda Hitz [1] *878*
VARIABILIDADE ESPACIAL DA DISPERSÃO RELATIVA DE VALORES INTERPOLADOS DO NDVI MEDIDO EM VIDEIRAS E MONITORADO EM CONDIÇÃO DE SATURAÇÃO 889
Bruno Ricardo Silva Costa [1]; Henrique Oldoni [2]; Luis Henrique Bassoi [3] *889*
RELAÇÃO ENTRE MAPA DE ZONAS DE POTENCIAL PRODUTIVO COM VARIÁVEIS DE SOLO DE INTERESSE AGRONÔMICO 895
LARA MARIE GUANAIS SANTOS [1]; MARIA DE FATIMA GUIMARÃES [2]; HEVANDRO COLONHESE DELALIBERA [3] *895*
ESCOLHA DO MELHOR MODELO DE APRENDIZADO DE MÁQUINA PARA A CLASSIFICAÇÃO DE SOLOS ARGILOSOS E ARENOSOS COM BASE EM IMAGENS 902
Gustavo Di Chiacchio Faulin [1]; Pedro Shuichi Hirata [2]; Thayna Lima Carvalho [2]; Marco António Ludovico Marques [3]; Marisa Silveira Almeida Renaud Faulin [1] *902*
DADOS GEOESPACIAS APLICADOS A AVALIAÇÃO DE PERDA DE SOLO 908
LAYANE CARMEM ARRUDA DA ROCHA [2]; MAYKON RODRIGO GOMES DE BARROS [1]; MICHEL CASTRO MOREIRA [3]; RICARDO SANTOS SILVA AMORIM [3] *908*
ELABORAÇÃO DE MAPAS DE PRODUTIVIDADE EM CITROS 913
Gabriel Villela Bedum [1]; Mateus Silva Gelain [1]; Eudocio Rafael Otavio da Silva [2]; Ricardo Canal Filho [2]; José Paulo Molin [3] *913*
7. Outros 920
EXPLORANDO A RELAÇÃO ENTRE MEDIDAS MORFOLÓGICAS E MASSA CORPORAL EM BOVINOS DE LEITE: UMA ANÁLISE POR ÁRVORE DE DECISÃO 921
Franck Morais de Oliveira [1]; Patricia Ferreira Ponciano Ferraz [2]; Gabriel Araujo e Silva Ferraz [3]; Jacqueline Cardoso Ferreira [4]; Ana Luiza Guimaraes Andre [5] *921*
ADOÇÃO DE FERRAMENTAS DE FRUTICULTURA DE PRECISÃO NA VITIVINICULTURA DO RIO GRANDE DO SUL 927
Teresa Enderle [1]; Júlia Faccin Faé [1]; Luís Felipe Rosseto Gerlach [1]; Gilmar Arduino Bettio Marodin [2]; André Luis Vian [2] *927*
VARIABILIDADE ESPACIAL DE DIÓXIDO DE CARBONO EM UMA INSTALAÇÃO PARA GADO LEITEIRO DO TIPO COMPOST BARN 932
Joao Victor Aguiar [1]; Patricia Ferreira Ponciano Ferraz [2]; Jacqueline Cardoso Ferreira [3]; Franck Morais de Oliveira [4]; Gabriel Araujo e Silva Ferraz [5] *932*
MODELAGEM DINÂMICA DA QUEDA DA SEMENTE DE SOJA EM SEMEADORAS DE PRECISÃO E IMPLICAÇÕES PARA A EQUIDISTÂNCIA LONGITUDINAL EM PLANTIO 940
Bruno Garlet Alberti [1]; Vinicius Kaster Marini [2] *940*
COMPETÊNCIAS NECESSÁRIAS AOS PROFISSIONAIS DA AGRICULTURA DIGITAL: REVISÃO DE LITERATURA E ENTREVISTAS 947
Lucia Maria Cuque [1]; João Augusto Mattar Neto [2] *947*

1. Agronomia/Manejo

UTILIZAÇÃO DE ÍNDICES ESPECTRAIS RGB NO MONITORAMENTO DE CULTIVO DE MILHO PARA SILAGEM

ANAIDE CAROLANE DA SILVA SANTOS [1]; MARCELO COELHO FURTADO [2]; GABRIEL FERREIRA DE OLIVEIRA [3]; MARIA EDUARDA GOMES [2]; MIGUEL JULIO MACHADO GUIMARÃES [4]

[1]Graduanda em Agronomia . BR-230, São Raimundo das Mangabeiras - MA, 65840-000. Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, São Raimundo das Mangabeiras; [2]Engº Agrônomo. BR-230, São Raimundo das Mangabeiras - MA, 65840-000. Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, São Raimundo das Mangabeiras; [3]Graduando em Agronomia . BR-230, São Raimundo das Mangabeiras - MA, 65840-000. Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, São Raimundo das Mangabeiras; [4]Engº Agrônomo, Doutor em Engenharia Agrícola, Professor. BR-230, São Raimundo das Mangabeiras - MA, 65840-000. Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, São Raimundo das Mangabeiras

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

O objetivo deste estudo foi avaliar a utilização índices de vegetação aplicados a imagens aéreas obtidas por uma aeronave remotamente pilotada no cultivo do milho para silagem. O experimento foi realizado no Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, em uma área experimental de 3,0 hectares, no ano de 2023. Foram realizadas coletas de imagens aéreas com uma aeronave remotamente pilotada em diferentes fases fenológicas da cultura. O processamento das imagens foi feito usando a técnica *Structure from Motion*, e o software foi QGIS 3.14 para aplicar os índices de vegetação NGRDI, GLI, VARI e NDVI. O cálculo no NDVI utilizando as imagens em formato RGB foi realizado através da conversão de pixels da banda do vermelho para o infravermelho próximo. Para determinar a produtividade do milho foram coletadas plantas em pontos georreferenciados na área de estudo. Após a aplicação dos índices de vegetação e da colheita, foram determinados os valores médios em cada ponto de amostragem da produtividade. Em posse dos dados, foi realizada a estatística descritiva das variáveis avaliadas. A utilização do NDVI adaptado com imagens na fração do visível (RGB) é uma alternativa viável e de baixo custo na avaliação de cultivos de milho silagem. Os índices de vegetação avaliados apresentam o mesmo comportamento quando utilizados para avaliar o desenvolvimento de cultivos de milho.

PALAVRAS-CHAVE: Drone; Índice de vegetação; Geoprocessamento

ABSTRACT

The aim of this study was to evaluate the use of vegetation indices applied to aerial images obtained by a remotely piloted aircraft in the cultivation of corn for silage. The experiment was carried out at the Federal Institute of Education, Science and Technology of Maranhão, in an experimental area of 3.0 hectares, in the year 2023. Aerial images were taken with a remotely piloted aircraft at different phenological stages of the crop. The images were processed using the *Structure from Motion* technique, and the software was QGIS 3.14 to apply the NGRDI, GLI, VARI and NDVI vegetation indices. NDVI was calculated using images in RGB format by converting pixels from the red band to the near infrared. To determine corn yield, plants were collected at georeferenced points in the study area. After applying the vegetation indices and harvesting, the average yield values at each sampling point were determined. Once the data was available, descriptive statistics were carried out on the variables evaluated. The use of NDVI adapted with images in the visible range (RGB) is a viable and low-cost alternative for evaluating corn silage crops. The vegetation indices evaluated show the same behavior when used to assess the development of maize crops.

KEYWORDS: Tomada de decisão;

INTRODUÇÃO

A produção global de milho para silagem é importante devido ao seu alto rendimento e valor nutricional. No Brasil, esta produção chegou a atingir aproximadamente 1,5 milhões de hectares cultivados no ano de 2016 (IBGE, 2017). Com isto, técnicas que visem facilitar o monitoramento destes cultivos vêm sendo desenvolvidas, sempre com o objetivo de auxiliar o produtor na tomada de decisão. Dentre as diversas técnicas desenvolvidas, o Sensoriamento Remoto (SR) é uma alternativa viável para estimar a biomassa vegetal em grandes áreas, proporcionando uma abordagem economicamente acessível devido a redução de custo com pessoas no campo para realizar o trabalho e maior praticidade na aquisição o dos dados (FASSNACHT et al., 2014). O SR é uma técnica que permite a obtenção de informações sobre objetos sem a necessidade de contato físico direto (HOLLE et al., 2022).

O SR permite que o monitoramento dos cultivos seja realizado à distância, facilitando assim a tomada decisões relacionadas à práticas agrícolas, conservação ambiental, gestão de recursos hídricos, entre outros. Como ferramenta do SR, o uso de aeronaves remotamente pilotadas (ARP) são fundamentais para mapear padrões de vegetação, calcular índices de biomassa e prever a produtividade das culturas agrícolas (DANTAS, 2022).

O uso de imagens aéreas adquiridas por ARPs é amplamente aplicado na agricultura, principalmente no monitoramento de lavouras. Através dos Índices de Vegetação é possível avaliar o estado das plantas, utilizando tanto o infravermelho próximo quanto imagens RGB. A escolha do método depende de fatores como resolução espacial e viabilidade econômica (VIEIRA, 2020).

OBJETIVOS

Com isto, o objetivo deste estudo foi avaliar a utilização índices de vegetação aplicados a imagens aéreas obtidas por câmera acoplada a aeronave remotamente pilotada no cultivo do milho para silagem.

MATERIAL E MÉTODOS

O experimento foi realizado no Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, Campus São Raimundo das Mangabeiras, a região apresenta clima do tipo Aw quente com estação seca no inverno e úmida no verão. Apresenta temperaturas médias anuais de 26,4 °C e precipitação média anual de 1157 mm. O solo do local é classificado como Latossolo Amarelo distrófico (SILVA, 2018). A área experimental de 3,0 hectares foi plantada com a variedade de milho BM 3066 em janeiro de 2023, com espaçamento de 0,20 m entre plantas e 0,40 m entre linhas. O preparo do solo incluiu correção com calcário de 1,4 t ha^{-1}, adubação no plantio utilizando ureia (50 kg ha^{-1}), superfosfato simples (667 kg ha^{-1}) e potássio (70 kg ha^{-1}), e na adubação de cobertura foi utilizado ureia (334 kg ha^{-1}) e cloreto de potássio (140 kg ha^{1}), conforme recomendações comerciais para a cultura do milho.

Foram realizadas coletas de imagens aéreas com uma ARP DJI Mavic Air 2S em diferentes fases fenológicas V18, R1, R2, R3 e R4 da cultura. Os voos foram feitos a 80 m de altura e 6 m/s de velocidade, com sobreposição de 80%. O processamento das imagens foi feito usando a técnica SFM (do inglês - *Structure from motion*) que realiza a reconstrução de estruturas tridimensionais a partir de sequências de imagens bidimensionais coletadas em sensores em movimento, e o software QGIS 3.14 para aplicar os índices de vegetação NGRDI (TUCKER, 1979), GLI (LOUHAICHI et al., 2001), VARI (GITELSON et al., 2002), NDVI (ALLEN et al., 2002; ARAI ET AL., 2016). O cálculo no NDVI utilizando as imagens em formato RGB é possível através da aplicação da metodologia

proposta por Arai et al. (2016), em que pixels da banda do vermelho são convertidos para o infravermelho próximo.

Para determinar a produtividade de biomassa fresca (PBF) do milho, amostras foram coletadas em 40 pontos georreferenciados utilizando o método posicionamento relativo cinemático, com um par de aparelhos GNSS do modelo FOIF A30. Em cada ponto de coleta colheu-se três plantas, as quais foram colocadas em sacos de papel e pesadas em balanças analíticas para determinação do peso de biomassa fresca, posteriormente foram secas em estufa de ventilação forçada a 65 °C para determinação do peso seco. Após a pesagem, os valores de produção foram multiplicados pelo estande da área para determinar a produtividade. Após a aplicação dos índices de vegetação, foram determinados os valores médios em cada ponto de amostragem da produtividade através da função Estatística zonais no software QGIS.

RESULTADOS E DISCUSSÃO

A Figura 1 apresenta a evolução do índice de vegetação e da produtividade de biomassa fresca e seca nas diferentes fases fenológicas do milho para silagem cultivado na região do Matopiba. A primeira avaliação foi realizada na fase V18, última fase vegetativa observada no cultivo. Pode-se observar uma estabilização, com leve redução, dos valores dos índices de vegetação nas fases reprodutivas.

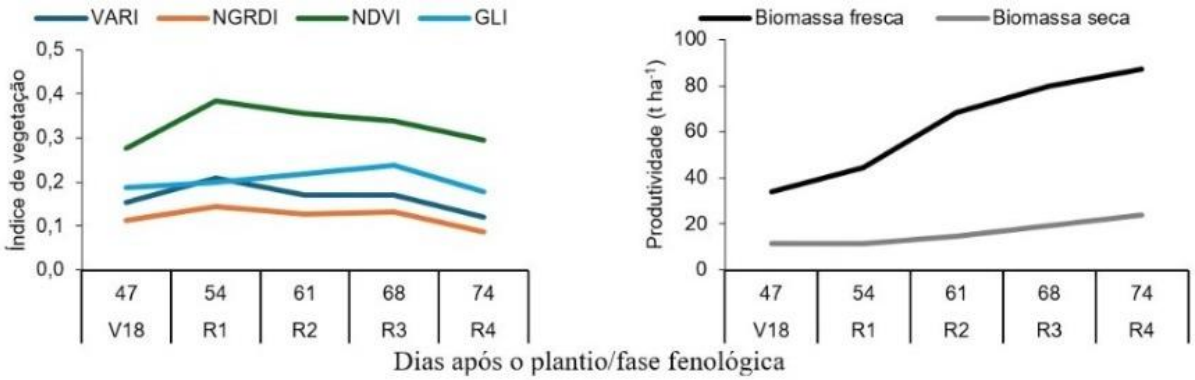


Figura 1 Índices de vegetação (A) e produtividade (B) de plantas de milho cultivado em sequeiro na região de São Raimundo das Mangabeiras.

Percebe-se que os maiores valores dos índices de vegetação são observados na fase R1, onde somente o índice GLI apresenta seu ápice aos 68 DAP (dias após o plantio), na fase R3. Resultado semelhante foi encontrado no trabalho realizado por BEIJO (2023), onde observou-se, de maneira geral, que é possível verificar que aos 50 DAP, praticamente todos os índices de vegetação saturam, mantendo similar relação espacial e que os maiores valores de índices foram encontrados entre os 50 a 55 DAP, período no qual a planta estava entre os estádios V18 a R1. Em relação à produtividade de biomassa (Figura 1B), a área apresentou aumento de biomassa fresca e seca até a fase R4, chegando a 87,31 t ha^{-1} e 24,04 t ha^{1} de biomassa fresca e seca, respectivamente. NEUMANN et al. (2018), trabalhando com milho silagem em três diferentes locais, obteve produções de biomassa seca entre 25 t ha^{-1} a 30 t ha^{-1}, mostrando que o potencial produtivo é afetado de acordo com a região de cultivo, valores estes próximos do encontrado no presente trabalho.

Os maiores valores médios de índice VARI, NGRDI e NDVI foram observados na fase R1. Já o índice GLI apresentou maior valor médio na fase R3 (Tabela 1). Tais valores observados são superiores aos encontrados nos trabalhos desenvolvidos por DANTAS (2022), o qual avaliou modelo espectral RGB para predição da produtividade de milho em São Raimundo das Mangabeiras, onde observou-se que a área avaliada apresentou valores médios dos índices próximos a 0,0621 para o NGRDI. A área avaliada apresentou uma alta variabilidade da produtividade de biomassa de milho

de acordo com os diferentes estágios fenológicos, pois, pode-se observar intervalos de PBF variando de 35,0 a 97,0 t ha^{-1}, nas fases R1 e R3, respectivamente. Já a PBS apresentou intervalos variando de 13,1 a 22,5 t ha^{-1} nas fases R1 e R4, respectivamente (Tabela 1).

Tabela 1 Estatística descritiva dos índices de vegetação e produtividade do milho obtidos para área de cultivo de milho em São Raimundo das Mangabeiras, Maranhão.

Variáveis	Fase fenológica																			
	V18				R1				R2				R3				R4			
	MED	MIN	MAX	DP	MED	MIN	MAX	DP	MED	MIN	MAX	DP	MED	MIN	MAX	DP	MED	MIN	MAX	DP
PBF	33,51	17,25	55,5	9,45	44,49	26	61	9,15	68,5	37,5	111,5	15,7	79,7	31,25	128,25	18,57	87,3	47,5	135,25	18,14
PBS	11,33	6,62	21	2,91	12,75	7,12	20,25	3	14,8	7	27,7	4,6	19,2	7,75	30	4,88	24	11,25	33,75	5,45
VARI	0,15	0,00096	0,36	0,08	0,2	0,09	0,31	0,04	0,17	0,09	0,25	0,03	0,17	0,05	0,26	0,04	0,11	0,03	0,23	0,05
NGRDI	0,11	0,0038	0,28	0,06	0,14	0,06	0,23	0,03	0,12	0,06	0,18	0,02	0,13	0,03	0,22	0,04	0,08	0,02	0,18	0,04
NDVI	0,27	0,007	0,51	0,12	0,38	0,26	0,49	0,05	0,35	0,21	0,49	0,06	0,33	0,19	0,53	0,07	0,29	0,16	0,48	0,08
GLI	0,18	0,07	0,28	0,06	0,19	0,11	0,28	0,03	0,21	0,13	0,27	0,03	0,23	0,11	0,33	0,04	0,17	0,1	0,28	0,04

Os resultados indicam que a variabilidade apresentada na PBF pode ter sido ocasionada pela variação da disponibilidade hídrica na área de cultivo, haja vista que a PBF é afetada diretamente pela quantidade de água disponível para a planta no momento da colheita. Os resultados corroboram com os estudos desenvolvidos por VIAN ET AL. (2016), os quais concluíram que a produtividade de milho apresenta elevada variabilidade espacial, e que esta variabilidade está condicionada por aspectos relacionados ao estabelecimento e desenvolvimento da cultura, bem como os fatores climáticos da região de cultivo.

Para ilustrar o desempenho dos índices avaliados na classificação dos alvos, foi selecionada uma área representativa do cultivo, cuja visualização foi ampliada para verificação de detalhes da superfície (Figura 2). O índice NDVI no estádio V18 obteve desempenho satisfatório ao destacar áreas de vegetação com maior vigor e solo exposto. Já os demais índices VARI, GLI, NGRDI apresentaram menor desempenho, principalmente nas bordas dos alvos (Figura 5). DANTAS (2022) em trabalho semelhante observou que os índices NGRDI e VARI obtiveram desempenho satisfatório ao destacar áreas de vegetação com maior vigor e solo exposto.

A utilização de imagens com bandas apenas no espectro RGB obtidas por RPA para estudos agronômicos abre um novo espaço para aplicação de técnicas do sensoriamento remoto na agricultura pelo baixo custo e facilidade em adquirir esse tipo de equipamentos (FREIRE-SILVA et al., 2019). É possível utilizar uma abordagem que visa criar conexões importantes entre a produtividade e a distribuição geográfica, aplicando-a no manejo em taxa variável. Isso implica observar áreas com maior variação espacial, o que ajuda a usar de forma mais eficiente os insumos ao longo do tempo.

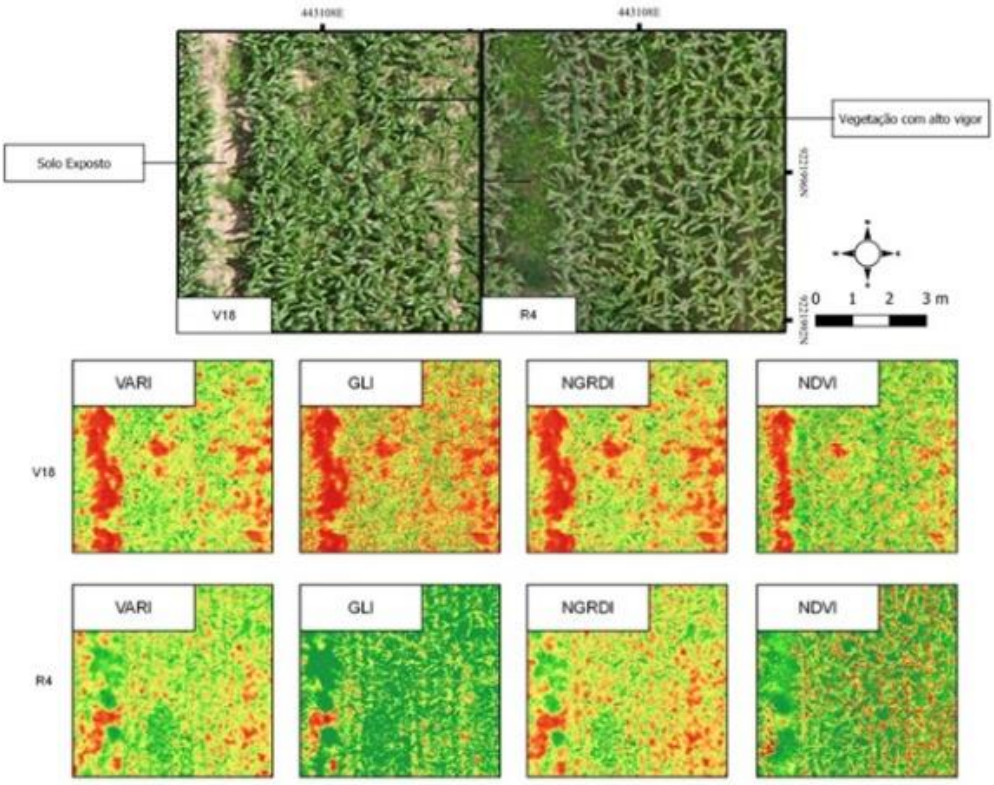


Figura 2 Detalhamento de área de cultivo de milho silagem, para identificação de alvos da superfície nos estádios fenológicos V18 e R4, em São Raimundo das Mangabeiras, Maranhão, 2023.

CONCLUSÃO

A utilização do NDVI adaptado com imagens RGB é uma alternativa viável e de baixo custo na avaliação de cultivos de milho silagem. Os índices de vegetação VARI, NGRDI, NDVI e GLI apresentam o mesmo comportamento quando utilizados para avaliar o desenvolvimento de cultivos de milho. Para trabalhos futuros, recomenda-se a avaliação dos cultivos em fases fenológicas iniciais, para assim avaliar o comportamento espectral de cultivos de milho durante todo o ciclo da cultura.

AGRADECIMENTOS

Ao Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, Campus São Raimundo das Mangabeiras, pelo apoio institucional.

REFERÊNCIAS

ALLEN, R. G.; TASUMI, M.; TREZZA, R. Satellite-Based energy balance for mapping evapotranspiration with internalized calibration (METRIC) - Model. **Journal of Irrigation and Drainage Engineering**, v. 133, p. 380-394, 2007.

ARAI, K.; GONDOH, K.; SHIGETOMI, O.; & MIURA, Y. Method for NIR reflectance estimation 637 with visible camera data based on regression for NDVI estimation and its application for 638 insect damage detection of rice paddy fields. **Int. J. Adv. Res. Artif. Intell**, v. 5, n. 11, 17-22, 2016.

BEIJO, M. M. D. Correlação espacial entre índices de vegetação e produtividade na cultura do milho. 2023. 22 f. Trabalho de Conclusão de Curso (Graduação em Agronomia) - Universidade Federal de Uberlândia, Uberlândia, 2023.

DANTAS, A. B. L. **Modelo espectral RGB para predição da produtividade de milho**. Monografia (Bacharel em Agronomia) - Instituto Federal de Educação Ciência e Tecnologia do Maranhão. São Raimundo das Mangabeiras, p. 37. 2022.

FASSNACHT, F. E.; HARTIG, F.; LATIFI, H.; BERGER, C.; HERNÁNDEZ, J.; CORVALÁN, P.; KOCH, B. Importance of sample size, data type and prediction method for remote sensing-based estimations of aboveground forest biomass. **Remote Sensing of Environment**, v. 154, p. 102-114, 2014.

FREIRE-SILVA, J.; PAZ, Y. M.; LIMA-SILVA, P. P.; PEREIRA, J. A.; CANDEIAS, A. L. Índices de vegetação do Sensoriamento Remoto para processamento de imagens na faixa do visível (RGB).Índices de vegetação do sensoriamento remoto para processamento de imagens na faixa do visível (RGB). **J. Hyperspectr. Remote Sens**, v. 9, p. 228-239, 2019.

GITELSON, A. A.; KAUFMAN, Y. J.; STARK, R.; RUNDQUIST, D. Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, v. 80, p. 76-87, 2002.

HOLLE, W.; VASCONCELLOS, B. N.; GEMIGNANI, B. H.; CORTE, A. P. D.; MALLMANN, A. A. Câmeras modificadas e multiespectrais embarcadas em drones: enfoque para estudos da vegetação. *In*: CÂMERAS modificadas e multiespectrais embarcadas em drones: enfoque para estudos da vegetação. 21. ed. Embrapa Florestas Colombo, PR: [*s. n.*], 2022. ISBN 1980-3958.

IBGE. **Censo Agropecuário.** 2017. Disponível em: < https://censoagro2017.ibge.gov.br/templates/censo_agro/resultadosagro/agricultura.html?localidade=0&tema=76547>. Acesso em: 29/08/2023.

LOUHAICHI, M.; BORMAN, M. M.; JOHNSON, D. E. Spatially located platform and aerial photography for documentation of grazing impacts on wheat. **Geocarto International**. v. 16, p. 65-70, 2001.

NEUMANN, M.; POCZYNEK, M.; LEÃO, G. F. M.; FIGUEIRA, D. N.; SOUZA, A. M. Desempenho de híbridos de milho para silagem cultivados em diferentes locais com três densidades populacionais. **Revista Brasileira de Milho e Sorgo**, v. 17, n. 1, p. 49-62, 2018.

SILVA, J. F. **Caracterização dos solos do Instituto Federal do Maranhão, Campus São Raimundo das Mangabeiras, região sul-maranhense**. Dissertação de mestrado. Universidade Estadual Paulista -UNESP. Câmpus de Jaboticabal - SP. 2018.

TUCKER, C. J.; MAXWELL, E. L. Sensor design for monitoring vegetation Canopies. **Photogrammetric Engineering and Remote Sensing,** v. 42, p. 1399-1410, 1976.

VIAN, A. L.; SANTI, A. L.; CARNEIRO AMADO, T. J.; CHERUBIN, M. R.; SIMON, D. H.; MELO DAMIAN, J.; BREDEMEIER, C. Variabilidade espacial da produtividade de milho irrigado e sua correlação com variáveis explicativas de plantas. **Ciência Rural**, Santa Maria. n3.V 46, 2016.

VIEIRA, V. A. G. M.; BARBOZA. **Índices de Vegetação Aplicados à Agricultura**. - Tangará da Serra: UNEMAT, 2020. v.05, n.01. 12p. Il. (Boletim Técnico Grupo de estudos em geotecnologias aplicadas às mudanças climáticas e agricultura digital- GeoClimaMT) ISSN: 2595-8550.

PRODUTIVIDADE DA CANA-DE-AÇÚCAR EM FUNÇÃO DA APLICAÇÃO DE DIFERENTES DOSES DE NITROGÊNIO, COM BASE NAS VARIAÇÕES DA CONDUTIVIDADE ELÉTRICA APARENTE (CE_a) DO SOLO

Guilherme Martineli Sanches [1]; Hugo Miranda Faria [4]; Almir Salvador Neto [5]; Rafael Otto [2]; José Eduardo Corá [3]

[1]Pós Doutorando. Av. Padua Dias, 11. Piracicaba, São Paulo, Brasil. Escola Superior de Agronomia 'Luiz de Queiroz; [2]Professor. Av. Padua Dias, 11. Piracicaba, São Paulo, Brasil. Escola Superior de Agronomia 'Luiz de Queiroz; [3]Professor. Via de Acesso Professor Paulo Donato Castelane S/N, Jaboticabal, São Paulo, Brasil. Faculdade de Ciências Agrárias e Veterinárias (FCAV/UNESP); [4]Doutor. Via de Acesso Professor Paulo Donato Castelane S/N, Jaboticabal, São Paulo, Brasil. Faculdade de Ciências Agrárias e Veterinárias (FCAV/UNESP); [5]Doutor. Via de Acesso Professor Paulo Donato Castelane S/N, Jaboticabal, São Paulo, Brasil. Faculdade de Ciências Agrárias e Veterinárias (FCAV/UNESP)

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A expansão da produção de cana-de-açúcar está relacionada ao aumento do consumo de fertilizantes nitrogenados (N), o que contribui para maiores emissões de gases de efeito estufa (GEE). Se o manejo dos fertilizantes N não for realizado de forma adequada, os impactos ao meio ambiente podem ser prejudiciais. A abordagem oferecida pela Agricultura de Precisão (AP) para mapeamento da variabilidade espacial do solo por meio de sensores eletromagnéticos pode contribuir significativamente para racionalizar a aplicação de insumos, incluindo o N, apesar de poucos estudos abordarem o tema na literatura. A condutividade elétrica aparente do solo (CE_a) tem sido destacada como uma ferramenta poderosa no mapeamento do potencial produtivo e da fertilidade do solo. O objetivo deste estudo foi avaliar a responsividade da cana-de-açúcar em termos de produtividade e fertilização nitrogenada em função da variabilidade espacial do solo identificada pela CE_a. Campos experimentais foram avaliados em duas áreas de cana-de-açúcar com diferentes tipos de solos durante dois ciclos de cultivo. Diferentes regiões de CE_a, denominadas plot HC (alta condutividade elétrica) e plot LC (baixa condutividade elétrica), foram avaliadas por parcelas experimentais delineadas em blocos casualizados com parcela controle mais 4 doses de N em 4 repetições. Os resultados mostraram que locais com maior CE_a (plot HC) apresentaram produtividades maiores do que locais com menor CE_a (plot LC) em ambas as áreas de estudo. Os plots HC necessitaram de doses menores de N para atingir o potencial máximo de produtividade que os plots LC. A área 1, caracterizada por maiores teores de argila, apresentou teores ótimos de N menores em comparação à área de estudo 2, caracterizada por menores teores de argila. Esse achado evidencia que o potencial produtivo da cultura está intrinsecamente associado à adubação nitrogenada, onde menores doses de N podem ser aplicadas em locais com maior potencial. Além disso, os plots LC para a Área 1 (maiores teores de argila) apresentaram doses ótimas de N iguais a ~109 kg ha^{-1} de N, enquanto na Área 2 (menores teores de argila) as doses ótimas de N foram iguais a 134,30 kg ha^{-1} (1ª safra ciclo) e 185,70 kg ha^{-1} (2º ciclo da cultura). Dadas as presentes descobertas, ferramentas de mapeamento digital do solo, como a CE_a medida por sensores eletromagnéticos, que ajudam a otimizar as aplicações de N nos campos podem melhorar o manejo específico do local dos canaviais em direção a uma agricultura de baixo carbono e mais sustentável.

PALAVRAS-CHAVE: nitrogênio; manejo localizado; sensoriamento proximal

ABSTRACT

The sugarcane production expansion are related with a nitrogen (N) fertilizers comsuption increment, which contributes to a higher greenhouse gas emissions. If the N fertilizers management is not carried out properly, the impacts on the environment can be harmful. The approach offered by Precision

Agriculture (PA) for mapping the soil spatial variability by eletromagentic sensors can significantly contribute to rationalize the application of inputs, including N, despite that few studies adressed the topic in the literature. Soil apparent electrical conductivity (EC_a) has been highlighted as a powerfull tool in the mapping of yield potential and soil fertility. The aim of this study was to assess the sugarcane responsiveness in terms of yield and nitrogen fertilization as a function of soil spatial variability identified by EC_a. Experimental fields were assessed in two sugarcane areas with different soils types during two crops cycles. Different EC_a regions, called plot HC (high electrical conductivity) and plot LC (low electrical conductivity) were assessed by experimental plots designed in randomized blocks with control plot plus 4 doses of N in 4 replications. The results showed that sites with higher EC_a (plots HC) showed higher yields than sites with lower EC_a (plots LC) in both study areas. Plots HC required a lower N rates to reach the maximum yield potential thans plots LC. Area 1, characterized by higher clay contents, showed optimal N rates lower compared to study area 2, characterized by lower clay contents. This finding evidences that the crop yield potential is intrinsically associated with N fertilization, where smaller N rates can be applied at places with greater potential. Additionally, LC plots for Area 1 (higher clay contents) showed optimal N rates equal to ~109 kg ha^{-1} of N, while Area 2 (lower clay contents) the optimal N rates was equal to 134.30 kg ha^{-1} (1^{st} crop cycle) and 185.70 kg ha^{-1} (2^{nd} crop cycle). Given the present findings, digital soil mapping tools, like EC_a measured by eletromagnetic sensors, that help to optimize the N applications on the fields can improve the site-specific management of sugarcane fields towards a low-carbon and more sustainable agriculture.

KEYWORDS: ;;

INTRODUÇÃO

O fato do solo ser o principal fornecedor de N para as plantas e a dificuldade de determinação dos teores no solo, tem levado pesquisadores em busca por ferramentas que possam auxiliar na otimização da aplicação de N na cultura de cana-de-açúcar, sendo uma delas a utilização de sensoriamento remoto (Amaral et al., 2015a). Valores de condutividade elétrica aparente do solo (CE_a), tem se mostrado adequados para avaliar a variabilidade de atributos químicos, físicos, umidade e temperatura do solo (Sudduth et al., 2005; Molin e Faulin, 2013; Ekwue e Bartholomew, 2011; Corwin e Lesch, 2005; McBratney et al., 2005), assim como seu potencial produtivo (Corwin e Lesch, 2005; Corwin e Lesch, 2003). Diante deste contexto, a caracterização da variabilidade espacial dos solos por meio dos sensores de CE_a podem auxiliar na otimização da aplicação de N na cultura de cana-de-açúcar de maneira rápida e eficiente, garantindo retorno econômico da produção.

A cana-de-açúcar é uma das culturas de maior destaque para regiões tropical e subtropical do planeta, por gerar produtos de alto valor agregado, considerados ecológicos e economicamente viáveis. Na última safra, o Brasil produziu, cerca de 637 milhões toneladas de cana-de-açúcar em uma área de aproximadamente de 8,4 milhões de hectares, sendo o estado de São Paulo responsável por mais de 50% da produção brasileira (CONAB, 2023).

Reconhecidamente, o adequado manejo do solo se correlaciona altas produtividades e longevidade dos canaviais. Atributos físicos, químicos e biológicos do solo, devem proporcionar para a planta um meio físico para que as raízes explorem maior volume possível de solo para poder absorver água e nutrientes para atender sua demanda, tendo como consequência a expressão plena de seu potencial produtivo. Destaca-se o nitrogênio, como um dos elementos essenciais em processos fisiológicos, intimamente ligados ao incremento de produtividade da cultura. Contudo, estudos mostram incertezas no diagnóstico para determinação do N no solo de modo possibilitar a forma mais eficiente e econômico de fornecimento para a planta (Mariano et al., 2017).

O método para determinação da recomendação de adubação nitrogenada tem como princípio a produtividade esperada da cultura (Spironello et al., 1997), pelo fato da dinâmica no elemento no solo

e falta de métodos de extração que atestem bom resultado de quantificação do elemento no solo. Resultados de pesquisas demonstram significativa diferença nas quantidades necessárias de N aplicadas ao solo, visando atender as necessidades nutricionais da planta: 120 a 200 kg ha^{-1} de N (Cantarella & Rossetto, 2014). Em muitos casos essa recomendação gera a aplicação de quantidades excessivas, sem a esperada resposta da cultura, que em condições de baixa umidade do solo, a ureia rapidamente volatiliza-se, de modo liberar óxido nitroso (N_2O) na atmosfera (Crutzen et al., 2008; de Vries & Bardgett, 2012; Soares et al., 2015). Assim, além da baixa eficácia da adubação, o excesso de N contribui para o efeito estufa, afetando no processo de efeitos das mudanças climáticas.

Diante desses fatos, a recomendação de adubação nitrogenada deve ser otimizada, levando-se em consideração outras fontes de variação como atributos do solo (Ex: pH, capacidade de troca catiônica, teor de matéria orgânica, teor de argila e densidade do solo); condições climáticas (temperatura e pluviosidade) e práticas agronômicas (preparo do solo e rotação de culturas) (Subbarao et al., 2006). Otto et. al (2016) observaram que a manutenção dos restos vegetais deixados pela cultura na superfície do solo, o aproveitamento de resíduos industriais e rotação com leguminosas, são fatores que podem diminuir a resposta da cana-de-açúcar à adubação nitrogenada. Adicionalmente, estudos comprovaram que o fator solo, e não o fertilizante, é o principal fornecedor de N para a cultura de cana-de-açúcar (Dourado-Neto et al., 2010; Franco et al., 2011; Vieira-Megda et al., 2015), o que explica parte da baixa eficiência da adubação nitrogenada observada.

OBJETIVOS

A hipótese do presente trabalho foi que a variabilidade espacial da condutividade elétrica aparente do solo permite definir regiões na lavoura para otimização da resposta da cultura de cana-de-açúcar à adubação nitrogenada. Portanto, o objetivo do trabalho foi investigar a resposta da cultura de cana-de-açúcar, em termos de produtividade e nitrogênio acumulado, à adubação nitrogenada em função da variabilidade espacial do solo identificada pela condutividade elétrica aparente (CE_a), buscando trazer novos resultados que permitam maximizar a aplicação de N.

MATERIAL E MÉTODOS

Áreas de Estudo

As áreas de estudo estão localizadas, no município de Ipaussu-SP (área 1 - 23º02'30,25" S - 49º34'40,66" O) e no município de Monte Alto-SP, (área 2 - 21º13'18,20" S - 48º27'41,97" O). O solo da área 1 foi classificado como Latossolo Vermelho distroférrico e da área 2 como Argissolo Vermelho Amarelo eutrófico. A variedade de cana-de-açúcar, utilizada na área 1 foi a RB966928 e na área 2 foi a variedade CTC 9005HP. Em ambas as áreas, a CE_a foi mensurada no espaçamento de 1,0m entre bobinas utilizando-se o sensor de indução eletromagnética (IEM) EM38-MK2® (Geonics, Ontario, Canada), tracionado por quadriciclo e conectado a receptor de GPS. Posteriormente, foi elaborado o mapa temático da distribuição espacial da CE_a, das respectivas áreas (Figura 1), utilizando-se método de interpolação krigagem ordinária. Em ambas as áreas, foram definidas zonas de alta CE_a, cujos valores encontravam-se acima do valor da mediana do conjunto dos dados e, áreas de baixa CE_a, cujos valores encontravam-se iguais ou abaixo da mediana dos dados.

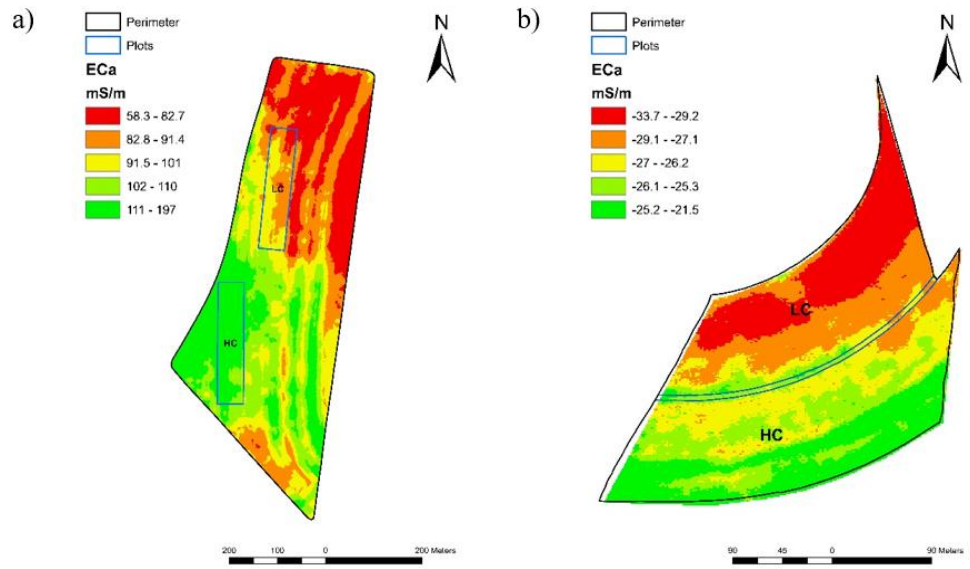


Figura 1. Mapa temático da CE_a da área experimental 1 (a) e área experimental 2 (b). Área de estudo 1 os *Plots* HC e LC correspondem aos locais com alta e baixa condutividade elétrica aparente, respectivamente.

Delineamento Experimental

Área 1

Na área de estudo 1, os tratamentos (doses de N) foram estabelecidos nas zonas consideradas de alta e de baixa CEa. As doses de N foram 50, 100, 150 e 200 kg ha^{-1} e um tratamento controle (sem adubação). A fonte de N utilizada foi o nitrato de amônio (NH_4NO_3). As aplicações do N foram realizadas em outubro de 2019 e novembro de 2020, 150 dias após a colheita - 150 DAC, correspondendo ao segundo (primeira soca) e terceiro (segunda soca) ciclo da cultura, respectivamente. O delineamento estatístico foi em blocos casualizados com 4 repetições. Cada parcela foi constituída de 6 linhas de cana-de-açúcar com 40 metros de comprimento, sendo as 4 linhas centrais consideradas área útil da parcela e as 2 linhas laterais as bordaduras.

Área 2

Na área de estudo 2, o experimento foi instalado, seguindo delineamento em blocos casualizados, com treze tratamentos e quatro repetições. Os tratamentos foram doses de N e um controle (sem aplicação de N) e dois momentos de aplicação, durante o segundo (primeira soca) e terceiro (segunda soca) ciclos da cultura. As doses de N foram de 50%, 100%, 150% e 200% da dose de N utilizada usualmente na cultura de cana-de-açúcar, as quais corresponderam a 54, 109, 163 e 218 kg ha^{-1} de N, respectivamente. A fonte de N, utilizada foi a ureia. Os momentos de aplicação do fertilizante nitrogenado foram: 1) dose total logo após a colheita (E1); 2) metade da dose logo após a colheita e a outra metade quando a cultura se encontrava com aproximadamente 1,0 m de altura. (E2); 3) dose total quando a cultura se encontrava com aproximadamente 1,0 m de altura (E3). Cada parcela (900 m^2) foi constituída de quatro linhas de cana-de-açúcar com 150 m de comprimento, espaçadas de 1,5 m, sendo as duas linhas centrais consideradas a área útil da parcela e as duas linhas laterais as bordaduras.

Avaliações

Solo

Em ambas as áreas de estudo foram coletadas amostras de solo visando caracterização de atributos químicos e da granulometria do solo. As amostras foram coletadas nas camadas de 0,00-0,20 m e 0,20-0,40 m. Nas amostras foram determinados, granulometria, valores de pH e teores de Ca, Mg, K, P, H+Al, e matéria orgânica. Com os resultados foram calculados capacidade de troca de cátions do solo (CTC), soma de bases do solo (SB) e porcentagem de saturação por bases na CTC do solo, conforme descrito em Raij et al. (2001).

Produtividade

A produtividade da cana-de-açúcar de cada área foi avaliada ao final do ciclo da cultura. Para tal, o corte da cana foi realizado mecanicamente e o transporte utilizando-se transbordo instrumentado com células de carga. A massa de colmos de cada parcela foi convertida em produtividade (Mg ha^{-1}).

Análise de Dados

A primeira fase da análise dos dados, teve como objetivo a identificação de valores discrepantes ("*outliers*") que poderiam afetar as análises posteriores. Valores maiores ou menores que 3 desvios padrão da média foram considerados como *outliers* para todos os dados coletados em campo e laboratório. Após exclusão dos valores discrepantes, os dados foram submetidos à análise descritiva (medidas de tendência central e dispersão, incluindo média, mediana, desvio padrão, coeficiente de variação, máximo e mínimo, assimetria e curtose) e análise de variância (ANOVA), neste último caso, visando verificar o efeito da adubação nitrogenada na CE_a, nos atributos do solo avaliados e na produtividade da cultura. Quando estatisticamente diferentes, as médias dos tratamentos foram comparadas pelo teste de Tukey (*p-value* < 0,05). Adicionalmente, o coeficiente de *Pearson* (*r*) foi utilizado para verificar a correlação entre as variáveis. Por fim, para cada área experimental, os dados de produtividade da cultura foram ajustados ($\alpha = 0,05$) à modelos de regressão em função das doses de N.

RESULTADOS E DISCUSSÃO

Na área experimental 1, maiores valores dos atributos químicos e de granulometria do solo foram observados onde valores da CE_a se mostraram mais elevados (*plot* HC), com exceção do teor de P na camada 0,00 - 0,20 m. (Tabela 1). Já na área experimental 2, o inverso foi observado, ou seja, menores valores dos atributos foram observados onde a CE_a se encontrava com maiores valores (-25,58 mS m^{-1}), com exceção para os teores de P, em ambas as camadas, e de Mg, na camada 0,00 - 0,20 m. Segundo Killick (2013), valores de condutividade elétrica negativa seria teoricamente impossível. No entanto, a medição indireta de CE_a, como a proporção de campos magnéticos secundários para primários em IEM, pode produzir medições negativas quando, por exemplo, acontece interferência de objetos de metal ou quando a calibração não foi feita adequadamente. Contudo, valores negativos de CE_a podem ser obtidos, sem que haja interferência de objetos de metal ou mesmo após correta calibração do instrumento de IEM, como mostrado em estudos de Cursi et al., (2021) e Sanches et al. (2022).

Tabela 1. Teores de fertilidade química e física do solo e da condutividade elétrica aparente (CEa) dos *plots* HC e LC das áreas de estudo 1 e 2 nas camadas 0,00-0,20 m e 0,20-0,40 m.

Plot	**Argila**	**pH**	**MO**	**P**	**K**	**Ca**	**Mg**	**SB**	**CTC**	**V%**	**CEa**
	g kg^{-1}		mg dm^{-3}			mmol dm^{-3}				%	mS m^{-1}
					Área 1						(0,00 - 0,75 m)
					(0,00 - 0,20 m)						

HC	610	5,7	30	24	2,3	71	21	94,3	122,3	77	35,46
LC	606	5,2	25	14	1,6	37	10	48,6	90,6	54	24,69
					(0,20 - 0,40 m)						
HC	633	5,7	27	16	1,9	53	16	70,9	104,9	68	-
LC	605	4,5	22	17	1,2	18	6	25,2	89,2	28	-
					Área 2						(0,00 - 0,75 m)
					(0,00 - 0,20 m)						
HC	108	5,6	-	22	1,1	25	13	38,7	56,6	68	-25,58
LC	143	5,8	-	19	1,3	28	11	40,5	56,2	72	-29,08
					(0,20 - 0,40 m)						
HC	123	5,6	-	21	0,8	22	11	33,6	51,8	65	-
LC	160	5,7	-	19	1,1	25	13	38,7	56,6	68	-

MO: matéria orgânica, P: fósforo, K: potássio, Ca: cálcio, Mg: magnésio, SB: soma de bases, CTC: capacidade de troca catiônica, V%: saturação por bases e CEa: condutividade elétrica aparente.

Apesar das diferenças, em termos absolutos, nos atributos do solo entre os campos experimentais HC e LC (Tabela 1) para ambas as áreas avaliadas, é possível notar que isso se refletiu na produtividade da cultura nos anos avaliados (Tabela 2). Para a área 1, enquanto o *plot* HC produziu 97,53 Mg ha^{-1} e 82,91 Mg ha^{-1} (média de 90,22 Mg ha^{-1} ano^{-1}) para os anos 1 e 2, respectivamente, o *plot* LC produziu 89,63 Mg ha^{-1} e 71,14 Mg ha^{-1} (média de 80,39 Mg ha^{-1} ano^{-1}) para o primeiro e segundo ano, respectivamente. Já para a área 2, enquanto o *plot* HC produziu para ambos os anos 1 e 2, respectivamente, 85,18 Mg ha^{-1} e 86,79 Mg ha^{-1} (média de 85,93 Mg ha^{-1} ano^{-1}), o *plot* LC produziu 81,11 Mg ha^{-1} e 92,83 Mg ha^{-1} (média de 86,97 Mg ha^{-1} ano^{-1}) para o primeiro e segundo ano, respectivamente. Esses dados correspondem a aproximadamente +4,9 Mg ha^{-1} ano^{-1} e -0,5 Mg ha^{-1} ano^{-1} de diferença entre o *plot* HC e LC para as áreas de estudo 1 e 2, respectivamente. Fica evidente assim que a produtividade apresenta uma correlação direta com o tipo de solo em função da CE_a, onde manchas de alta CE_a (*Plot* HC) apresentaram menores produtividade na área de estudo 2, caracterizada por ser um Argissolo.

Tabela 2. Estatística descritiva da produtividade nas áreas de estudo 1 e 2 nos campos experimentais de alta (*Plot* HC) e baixa (*Plot* LC) condutividade elétrica aparente do solo.

	Média	**Mediana**	**Min.**	**Máx.**	**SD**	**CV**
			AREA 1			
			Safra 2019/2020			
Plot HC	97.53	98.06	82.78	109.44	7.30	7.49
Plot LC	89.63	90.07	66.25	108.33	10.75	12.00
			Safra 2020/2021			

Plot HC	82.91	84.86	59.72	108.33	12.16	14.66
Plot LC	71.14	71.67	45.83	98.33	13.63	19.16
			ÁREA 2			
			Safra 2019/2020			
Plot HC	85.18	83.23	77.08	96.05	7.60	8.92
Plot LC	81.11	80.71	67.84	93.67	9.31	11.47
			Safra 2020/2021			
Plot HC	86.79	86.74	80.13	93.68	4.79	5.52
Plot LC	92.83	95.36	81.14	99.72	7.06	7.60

Min.: mínimo, Máx.: Máximo, DP: Desvio Padrão, CV: Coeficiente de variação, CEa: Condutividade elétrica aparente, Prod.: Produtividade. Unidades: Produtividade [Mg ha^{-1}] e CEa [mS m^{-1}]

No *plot* HC a produtividade correlacionou-se positivamente com a CE_a para o primeiro e segundo ano (r = 0,51 e 0,49, respectivamente). Já para a área 2, apenas a produtividade do primeiro ano de avaliação correlacionou-se positivamente com a produtividade no *plot* HC (r = 0,43). As doses de N apresentarem diferença estatística significativa, em termos de produtividade, para o plot HC no primeiro ano de avaliação na área de estudo 2 e para o plot LC no segundo e primeiro ano de avaliação nas áreas de estudo 1 e 2, respectivamente (Tabela 3). Apenas para o segundo ano da área de estudo 1 houve diferença estatística significativa na produtividade entre os plots HC (82,91 Mg ha^{-1}) e LC (71,14 Mg ha^{-1}). Com exceção do segundo ano de avaliação da área de estudo 2, o plot HC sempre foi superior ao plot LC em termos de produtividade, apesar de estatisticamente não ocorrer diferenças significativas.

Tabela 3. Análise de variância da produtividade nos campos experimentais de alta (*plot* HC) e baixa (*plot* LC) condutividade em função das doses de nitrogênio aplicadas nas áreas de estudo 1 e 2.

					Produtividade (Mg ha^{-1})				
		Área 1					**Área 2**		
					Plot HC				
Dose	*Ano 1*		*Ano 2*		**Dose**	*Ano 1*		*Ano 2*	
0	100.00	a	91.11	a	**0**	96.05	a	80.13	a
50	103.89	a	79.91	a	**54**	77.08	b	86.64	a
100	96.39	a	88.52	a	**109**	83.23	ab	86.77	a
150	93.33	a	80.00	a	**163**	89.38	a	93.68	a
200	94.03	a	75.00	a	**218**	80.13	b	86.74	a
Média	97.53	A	82.91	A	**Média**	85.18	A	86.79	A
					Plot LC				

0	88.06	a	58.06	b	**0**	67.84	b	81.14	a
50	90.94	a	74.81	ab	**54**	84.10	ab	95.36	a
100	91.46	a	79.13	a	**109**	80.71	ab	95.73	a
150	89.90	a	81.94	a	**163**	93.67	a	92.20	a
200	87.81	a	61.76	ab	**218**	79.26	ab	99.72	a
Média	89.63	A	71.14	B	**Média**	81.11	A	92.83	A

Unidades: Dose [kg ha^{-1}], Produtividade [Mg ha^{-1}]. Letras minúsculas diferem as doses de N. Letras maiúsculas diferem os *plots* HC e LC.

Avaliando-se a regressão das doses de N em função da produtividade para a área de estudo 1, em ambos os anos avaliados, o *plot* HC ajustou-se ao modelo linear e o *plot* LC ao modelo quadrático (Figura 2b), sendo que no *plot* HC as maiores doses corresponderam a menores produtividades (Figura 2). Já para a área de estudo 2 as doses se ajustaram ao modelo quadrático no *plot* LC para ambos os anos avaliados, sendo que no *plot* HC apenas o ano de 2019 ajustou-se ao modelo quadrático. Na área de estudo 1 o *plot* HC ajustou-se ao modelo linear negativamente em ambos os anos avaliados. No ajuste quadrático no *plot* LC de ambas as áreas e ambos os anos avaliados foi derivado o ajuste quadrático para se encontrar uma dose ótima de N a ser aplicada. Encontrou-se os valores de 109,30 kg ha^{-1} e 109,50 kg ha^{-1} (área 1), 134,30 kg ha^{-1} e 185,70 kg ha^{-1} (área 2) para o primeiro e segundo ano de avaliação, respectivamente.

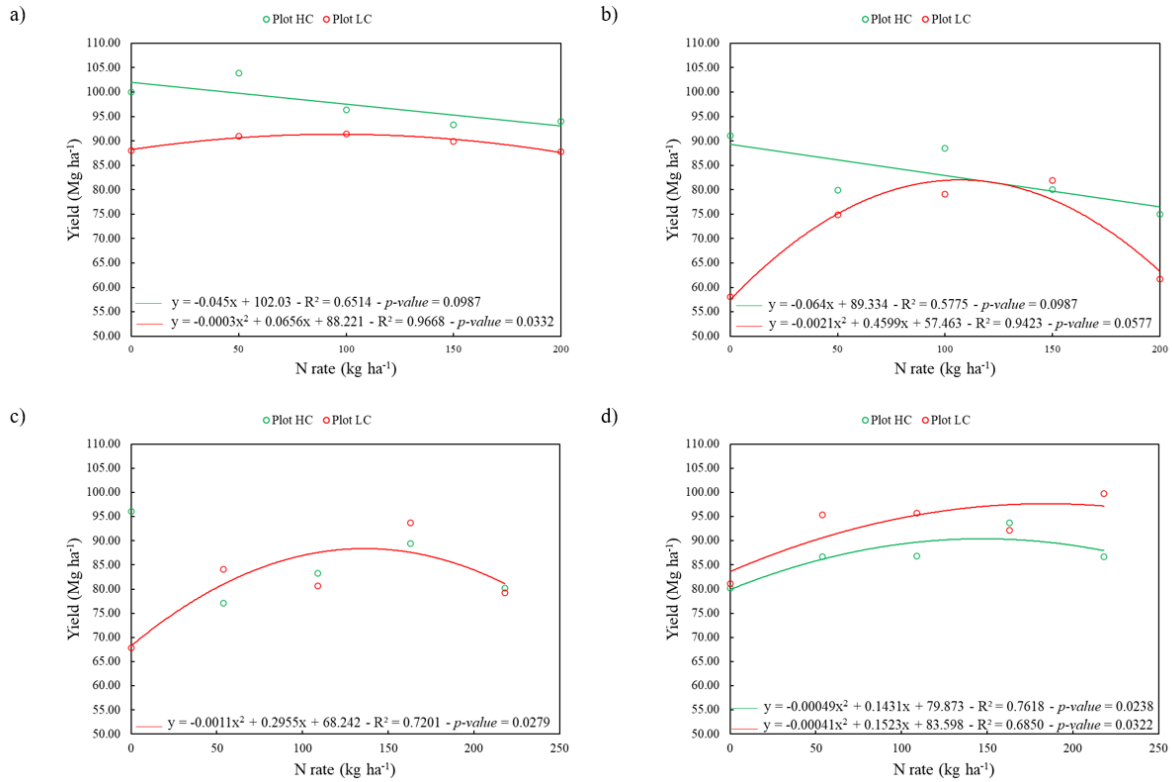


Figura 2. Ajuste linear e quadrático da produtividade em função das doses de nitrogênio para os campos experimentais de alta (plot HC - verde) e baixa (plot LC - vermelho) condutividade na área de estudo 1 para os anos de 2020 (a) e 2021 (b) e na área de estudo 2 para os anos de 2019 (c) e 2020 (d).

DISCUSSÃO

O uso da CE_a para avaliação da variabilidade espacial do solo nos campos de cultivo tem sido uma ferramenta cada vez mais difundida nas lavouras do Brasil (Sanches et al., 2022) e do mundo (Rossel & Bouma, 2016). No Brasil, esta ferramenta tem sido utilizada para avaliação da variabilidade espacial do conteúdo de argila e matéria orgânica do solo (Sanches et al., 2022), pH do solo (Sanches et al., 2018), potencial produtivo da lavoura (Sanches et al., 2019) e definição de zonas de manejo (Grego et al., 2022). No entanto, estudos para avaliar o potencial de aplicação desta tecnologia associada a reposta da cultura à adubação nitrogenada ainda são escassos.

Altamente correlacionada com o conteúdo de argila, conforme apresentado no presente estudo (Tabela 1) e, consequentemente, com o potencial produtivo da lavoura (Tabela 2), a CE_a pode ser uma ferramenta auxiliar nas recomendações de nitrogênio nas lavouras de cana-de-açúcar. No entanto, foi observado que atributos do solo também apresenta influência sobre a CE_a, conforme observado para a área 2, onde o conteúdo de argila foi maior para os plots de baixa condutividade (plot LC). A classe de solo de ocorrência na área 2, um Argissolo, apresenta nas camadas superficiais maiores teores de areia e, consequentemente, menores teores dos atributos químicos. Isso explica o fato de locais de alta condutividade (*plot* HC) possuírem menor de fertilidade. Para a área 1, apesar do solo se encontrar na faixa de textura muito argilosa para ambos os *plots* avaliados, é possível observar que a pequena diferença no conteúdo de argila (4 g kg^{-1} na camada 0,00 - 0,20 m) foi detectada pela mensuração da CE_a do solo pelo equipamento de IEM, evidenciando ser uma ferramenta com alto potencial de aplicação na definição do potencial produtivo da lavoura. Para a área 2, apesar da correlação inversa entre CE_a e textura do solo, é possível notar também a diferença nos níveis de fertilidade entre os *plots* avaliados.

Associada aos atributos do solo que definem o potencial produtivo da lavoura, conforme relatado anteriormente, em termos qualitativos a CE_a mostra-se como um excelente parâmetro para distinção da produtividade nas regiões da lavoura (Sanches et al., 2022). No entanto, em termos quantitativos, sua correlação com a produtividade mostrou-se positiva somente no *plot* HC, evidenciando que regiões de baixa condutividade, caracterizadas por menores teores relativos de fertilidade, podem existir outros fatores governando a produtividade da lavoura além da fertilidade do solo. Por outro lado, em termos da resposta da cultura à adubação nitrogenada, nos plots HC, caracterizado pela alta condutividade e por teores mais elevados de fertilidade do solo, o presente estudo evidenciou que podem ser aplicadas doses menores de N para manutenção da produtividade da lavoura (Figura 2). Já nos plots LC o presente estudo mostrou que uma dose ótima pode ser definida. Ainda, na área de estudo 1, caracterizada pelo alto teor de argila, verifica-se doses ótimas menores de N em relação a área de estudo 2.

O trabalho recente de Sanches & Otto (2022) e os da presente pesquisa indicam que áreas com maior potencial produtivo são menos responsivas às doses de N. Se isso for verdade, para a maioria das áreas cultivadas com cana-de-açúcar, o critério de recomendação de adubação por expectativa de produtividade, utilizando um único fator de adubação para diferentes níveis de produtividade, pode não somente estar penalizando a produtividade nos ambientes mais restritivos, como superdimensionando a adubação de soqueira nos ambientes mais produtivos. Apesar das recomendações de adubação nitrogenada baseadas no conceito de produtividade esperada serem adotadas há mais de 50 anos em todo Estados Unidos e em diversas outras regiões do mundo, a definição dos fatores de uso de N foi baseada em poucos princípios agronômicos (Rodriguez et al., 2019). A principal vantagem dos sistemas de recomendação de adubação baseados na produtividade esperada é a facilidade em sua interpretação o que facilitou sua adoção em larga escala (Morris et al., 2018). Porém, na maioria das vezes não tem um embasamento agronômico sólido e pode levar a subdimensionamento ou superdimensionamento das adubações, como mostra o presente resultado. O mesmo pode estar ocorrendo indiscriminadamente quando são utilizados os fatores de 1,0 kg N Mg^{-1} adotado anteriormente em cana-queimada ou 1,2 kg N Mg^{-1} usualmente empregado para cana-crua nas condições brasileiras.

Apesar de métodos de recomendação de N baseados em análise de solo serem buscados há décadas, até o momento ainda não foram adotados em larga escala. Ultimamente, estudos tem obtido resultados animadores para o uso de métodos de recomendação baseados em testes no solo (Franzluebbers, 2018; McDaniel et al., 2020). Porém, para cana-de-açúcar cultivada no Brasil, apesar dos resultados mais animadores apresentados por Otto et al. (2013), nenhum método foi útil em identificar a dose de N a ser utilizada para adubação de soqueira de cana-de-açúcar (Mariano et al., 2017). Pode ser que no futuro algum método possa ser utilizado para recomendação da adubação nitrogenada da cana-de-açúcar, mas avanços são necessários para calibrar estes métodos em condições de campo. Diante deste contexto, ferramentas que auxiliem na otimização da aplicação de N, como os indícios apresentados aqui por meio da mensuração da variabilidade espacial da CE_a, podem melhorar o manejo dos canaviais brasileiros rumo a uma agricultura de baixo carbono e mais sustentável.

CONCLUSÃO

Os resultados da presente pesquisa mostram que é possível utilizar o mapeamento da condutividade elétrica aparente (CE_a) do solo para otimização das doses de N nas lavouras de cana-de-açúcar. Nos locais de alta CE_a (*plot* HC), a produtividade foi superior em relação aos locais de baixa CE_a (plot LC) em ambas as áreas de estudo, com exceção na área de estudo 2, do ano de 2020. Para os plots HC foi possível verificar a necessidade de menores doses de N para se atingir o máximo potencial produtivo. Na área de estudo 1, caraterizada pelo alto teor de argila, as doses ótimas de N são menores em comparação a área de estudo 2, caracterizada pelos menores teores de argila. Tal fato mostra que o potencial produtivo da lavoura pode estar intrinsicamente associado a fertilização nitrogenada, onde doses menores de N podem ser aplicadas em locais de maior potencial. Colaborando com isso, nos *plots* LC, enquanto na área de estudo 1 (maiores teores de argila) a dose ótima foi igual a ~109 kg ha^{-1} de N, na área 2 a dose ótima foi igual a 134,30 kg ha^{-1} (1º ano) e 185,70 kg ha^{-1} (2º ano). Diante dos resultados encontrados, ferramentas que auxiliem na otimização da aplicação de N, como os apresentados no presente trabalho, por meio da mensuração da variabilidade espacial da CE_a, podem melhorar o manejo dos canaviais brasileiros rumo a uma agricultura de baixo carbono e mais sustentável.

AGRADECIMENTOS

A presente pesquisa foi financiada pela Fundação de Âmparo à Pesquisa do Estado de São Paulo - FAPESP (Processos #2022/15875-1, #2016/13461-4, #2018/10225-3).

REFERÊNCIAS

Amaral, LR; Molin, JP; Schepers, JS. (2015). Algorithm for Variable-Rate Nitrogen Application in Sugarcane Based on Active Crop Canopy Sensor. Agronomy Journal 107:1513-1523.

Amaral, L. R.; Molin, J.P. (2014). The Effectiveness of Three Vegetation Indices Obtained from a Canopy Sensor in Identifying Sugarcane Response to Nitrogen. agronomy journal 106:273.

Cantarella, H; Rossetto, R. (2014). Fertilizers for sugarcane. In: Sugarcane bioethanol - R&D for Productivity and Sustainability. Cortez, LAB (Ed.). São Paulo: Edgard Blücher, p. 405-422.

Companhia Nacional do Abastecimento (CONAB). (2023). Acompanhamento da safra Brasileira. Cana-de-açúcar, SAFRA 2023/24 Primeiro Levantamento Abril/2023. Brasília, DF, 56p.

Corwin, D.L., Lesch, S.M. (2003). Application of soil electrical conductivity to precision agriculture: Theory, principles, and guidelines. Agronomy Journal, 95:455-471.

Corwin, D.L.; Lesch, S.M. (2005). Apparent soil electrical conductivity measurements in agriculture. Computers and Electronics in Agriculture, 46:11-43.Crutzen, P.J., Mosier, A.R., Smith, K.A., Winiwarter, W. (2008). N2O release from agro-biofuel production negates global warming reduction by replacing fossil fuels. Atmospheric Chemistry and Physics 8, 389-395.

Cursi, D.E., Gazaffi, R., Hoffmann, H.P., Brasco, T.L., Amaral, L.R., Dourado Neto, D. (2021). Novel Tools for Adjusting Spatial Variability in the Early Sugarcane Breeding Stage. Frontiers in Plant Science.

de Vries, F.; Bardgett, R. (2012). Plant-microbial linkages and ecosystem N retention: lessons for sustainable agriculture. Frontiers in Ecology and the Environment 10(8):425-432.Dourado-Neto, N.D., Powlson, D., Bakar, R.A., Bacchi, O.O.S., Basanta, M.V., Cong, P.T., Keerthisinghe, S., Ismaili, M., Rahman, S.M., Reichardt, K., Safwat, M.S.A., Sangakkara, R., Timm, L.C., Wang, J.Y., Zagal, E., Van, K.C. (2010). Multiseason recoveries of organic and inorganic nitrogen-15 in tropical cropping systems. Soil Sci Soc Am J 74:139-152.

Ekwue, E.; Bartholomew, J. (2011). Electrical conductivity of some soils in Trinidad as affected by density, water and peat content; Biosystems Engineering, 108(2): 95-103.

Empresa Brasileira de Pesquisa Agropecuária, EMBRAPA. (2018). Humberto G. dos. Sistema brasileiro de classificação de solos. 5 Brasilia: EMBRAPA, 2018, 356 p.mbrapa 2018

Franco, H.C.J., Otto, R., Faroni, C.E., Vitti, A.C., Oliveira, E.C.A., Trivelin, P.C.O. (2011). Nitrogen in sugarcane derived from fertilizer under Brazilian field conditions. Field Crops Research 121: 29-41.

Franco, H.C.J., Castro, S.G.Q., Sanches, G.M., Kölln, O.T., Bordonal, R.O., Borges, B.M.M.N., Borges, C.D. (2018). Alternatives to Increase the Sustainability of Sugarcane Production in Brazil under High Intensive Mechanization. In. Singh, P., Tiwari, A.K. Sustainable Sugarcane Production. Apple Academic Press - 426 p.

Franzluebbers, A.J. (2018). Soil Test Biological Activity with the Flush of CO2: III. Corn Yield Responses to Applied Nitrogen Soil Science Society of America Journal 82: 708-721.

Grego, C.R., Speranza, E.A., Rodrigues, C.A.G., Ronquim, C..C, Luchiari Junior, A., Sanches, G.M., P Vaz, C.M., Jorge, L.A. de C, PORTO, V.H.B. (2022). In: PIRES, JLF; BRANDAO, ZN (ed.). Experimentação on-farm na agricultura de precisão. Estudo de caso 6-zonas de manejo e adubação em área de cultivo de cana-de-açúcar na Fazenda Santa Helena, Ibaté, SP. Passo Fundo: Embrapa Trigo, 2022.

Jaynes, D.B. (2011). Confidence bands for measured economically optimal nitrogen rates Precis. Agric., 12 (2), 196-213.

Mariano, E.; Otto, R.; Montezano, Z.F.; Cantarella, H.; Trivelin, P.C.O. (2017). Soil nitrogen availability indices as predictors of sugarcane nitrogen requirements. European Journal ff Agronomy, 89:25-37.

Martins, DS; Reis, V.M.; Schultz; N.; Alves, B.J.R.; Urquiaga, S.; Pereira, W.; Sousa, J.S.; Boddey, R.B. (2020) Both the contribution of soil nitrogen and of biological N2 fixation to sugarcane can increase with the inoculation of diazotrophic bactéria. Plant Soil 454: 155-169.

McBratney, A.; Whelan, B.M.; Ancev, T.; Bouma, J. (2005). Future Directions of Precision Agriculture. Precision Agriculture, 6(1):7-23.McBratney et al.

McDaniel, MD; Walters, DT; Bundy, LG; Li, X; Drijber, RA; Sawyer, JE; Castellano, MJ; Laboski, CAM; Scharf, PC; Horwath, WR. (2020). Combination of biological and chemical soil tests best predict maize nitrogen response. Agronomy Journal 112: 1263-1278.

Molin, J.P.; Faulin, G.D.C. (2013). Spatial and temporal variability of soil eletrical conductivity related to soil moisture. Scientia Agricola, 70(1):1-5.

Morris, T. F., Murrell, T. S., Beegle, D. B., Camberato, J. J., Ferguson, R. B., Grove, J., et al. (2018). Strengths and Limitations of nitrogen rate recommendations for corn and opportunities for improvement. Agronomy Journal 110:1-37

Otto, R.; Castro, S.A.Q.; Mariano, E.; Castro, S.G.Q.; Franco, H.C.J.; Trivelin, P.C.O. (2016). Nitrogen use efficiency for sugarcane-biofuel production: what is the next? Bioenergy Research, 9(4):1272-1289.

Otto, R., Mulvaney, R.L., Khan, S.A., Trivelin, P.C.O. (2013). Quantifying soil nitrogen mineralization to improve fertilizer nitrogen management of sugarcane. Biology and Fertility of Soils 49:893-904.

Puntel, L.A., Pagani, A., Archontoulis, S.V. 2019. Development of a nitrogen recommendation tool for corn considering static and dynamic variables. European Journal of Agronomy 105:189:199.

Raij, B. van; Andrade, J.C.; Cantarella, H. & Quaggio, J.A., eds. Análise química para avaliação da fertilidade de solos tropicais. Campinas, Instituto Agronômico, 2001. 285p.

Rodriguez, D.G.P.; Bullock, D.S.; Boerngen, M.A. (2019). The Origins, Implications, and Consequences of Yield-Based Nitrogen Fertilizer Management. Agronomy Journal 111: 725-735.

Rossel, R.A.V., Bouma, J., (2016). Soil sensing: a new paradigma for agriculture. Agricultural Systems 148, 71-74.

Sanches, G.M.; Otto, R.; Adamchuk, V.; Magalhães, P.S.G. (2022). Spatial variability of soil attributes by an electromagnetic induction sensor: A framework of multiple fields assessment under Brazilian soils. Biosystems Engineering 216:229-240.

Sanches, G.M., & Otto, R. (2022). A novel approach for determining nitrogen requirement based on a new agronomic principle-sugarcane as a crop model. Plant & Soil 472, 29-43.

Sanches, G.M., Magalhães, P.S.G., Remacre, A.Z., & Franco, H.C.J. (2018). Potential of apparent soil electrical conductivity to describe the soil pH and improve lime application in a clayey soil. Soil & Tillage Research 175, 217-225.

Sanches, G.M., Franco, H.C.J., & Magalhães, P.S.G. (2019). Site-specific assessment of spatial and temporal variability of sugarcane yield related to soil attributes. Geoderma 334, 90-98.

Soares, J.R.; Cantarella, H.; Vargas, V.P.; Carmo, J.B.; Martins, A.A.; Sousa, R.M.; Andrade, C.A. (2015). Enhanced-Efficiency Fertilizers in Nitrous Oxide Emissions from Urea Applied to Sugarcane. Journal of Environmental Quality 44:423-430.

Spironello, A., B. Van Raij, C.P. Penatti, H. Cantarella, J.L.M. Morelli, J. Orlando Filho, M.G.A. Landell, R. Rosseto. (1997). Cultara da Cana-de-Açúcar. In: Raij, B.Van., H. Cantarella, J.A. Quaggio, A.M.C. Furlani. Recomendação de adubação e calagem para o Estado de São Paulo. 2.ed. Campinas: Instituto Agronômico. p.237-239. 1997

Subbarao, G.V.; Ito, O.; Sahrawat, K.L.; Bery, W.L.; Nakahara, K.; Ishikawa, T.; Watanabe, T.; Suenaga, K.; Rondon, M.; Rao, M. (2006). Scope and Strategies for regulation of nitrification in Agricultural Systems. Challenges and Opportunities Plant Sciences, v.25, p. 303-335.Sudduth, KA; Kitchen, NR; Wiebold, WJ; Batchelor, WD; Bollero, GA; Bullock, DG; Clay, DE; Palm, HL; Pierce, FJ; Schuler, RT; Thelen, KD. (2005). Relating apparent electrical conductivity to soil properties across the northcentral USA. Computers and. Electronics in Agriculture 46:263-283.

VARIABILIDADE ESPACIAL DA RESISTÊNCIA DO SOLO À PENETRAÇÃO

Jorge Wilson Cortez [1]; Diandra Pinto Della Flora [2]; Dario Alexandre Schwambach [3]
[1]Docente. RODOVIA DOURADOS-ITAHUM KM12. Universidade Federal da Grande Dourados; [2]Técnico. Av. Carlos Gomes, 222, Porto Alegre . TIMAC Agro; [3]Egresso. RODOVIA DOURADOS-ITAHUM KM12, Dourados - MS. Universidade Federal da Grande Dourados

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
A análise da compactação do solo por meio da determinação da resistência do solo à penetração (RP) é uma das técnicas mais práticas e utilizadas à campo. Assim, objetivou-se avaliar a variabilidade espacial da RP e da profundidade de ocorrência da resistência máxima em área comercial. A coleta de dados ocorreu em propriedade do Município de Ponta Porã - MS, em talhão de 135,74 ha. A grade amostral foi de 60 pontos regulares e 10 aleatórios. Para a coleta de dados da RP utilizou-se penetrômetro eletrônico até a profundidade de 0,40 m. Os dados foram analisados por meio da estatística descritiva e a geoestatística. Ocorre variabilidade espacial da resistência do solo à penetração (RP) principalmente nas camadas de 0,0-10 e 30-40 cm. Os valores médios de RP ficaram abaixo do limite critico de 3500 kPa. No entanto, o valor máximo da RP nos pontos indicou que a maior parte área apresentou compactação entre 3500-6000 kPa, acima do limite, necessitando de processo de remoção da camada compactada, sendo a maior parte da área essa compactação estava de 10-20 cm. Portanto, o uso do valor médio da RP pode levar a erro de interpretação do real estado de compactação do solo, devendo ser utilizado o valor máximo do ponto e sua profundidade.

PALAVRAS-CHAVE: compactação do solo; geoestatística; penetrômetro eletrônico

ABSTRACT
The analysis of soil compaction by determining soil resistance to penetration (PR) is one of the most practical techniques used in the field. Thus, the objective was to evaluate the spatial variability of the RP and the depth of occurrence of maximum resistance in a commercial area. Data collection took place on property owned by the Municipality of Ponta Porã - MS, in a plot of 135.74 ha. The sampling grid was 60 regular points plus 10 random ones. To collect RP data, an electronic penetrometer was used to a depth of 0.40 m. The data were analyzed using descriptive statistics and geostatistics. There is spatial variability of soil penetration resistance (PR) mainly in the 0.0-10 and 30-40 cm layers. The average RP values were below the critical limit of 3500 kPa. However, the maximum value of the PR at the points indicated that most of the area presented compaction between 3500-6000 kPa, above the limit, requiring a process of removal of the compacted layer, and most of the area this compaction was 10-20 cm. Therefore, the use of the average value of the PR can lead to an error in the interpretation of the real state of soil compaction, and the maximum value of the point and its depth should be used.

KEYWORDS: ;

INTRODUÇÃO

A resistência do solo à penetração pode ser impeditiva ao crescimento radicular, assim se faz necessário sua mensuração, principalmente em áreas de plantio direto. A análise da compactação do solo por meio da determinação da resistência do solo à penetração (RP) é uma das técnicas mais práticas e utilizadas à campo. A penetrometria é uma técnica rápida de fácil utilização principalmente com o uso de penetrômetros eletrônicos (FALKER, 2010). O equipamento consiste em uma haste

com ponta cônica que penetra no solo e converte a pressão exercida, em uma célula de carga, em resistência à penetração. Os limites críticos de RP foram estabelecidos por diversos pesquisadores, dentre os quais pode-se citar que segundo Ribeiro (2010) pode-se definir limites da RP para solos argilosos como: sem compactação (0-2 MPa), compactação tolerável (2-4 MPa), compactado (> 4,0 MPa) e muito compactado (> 6,0 MPa). Ainda nesse aspecto, Moraes et al., (2014) especifica valores de referência como limitantes ao desenvolvimento radicular de 3,5 MPa (3500 KPa) para área em plantio direto em solos argilosos. Cortez et al. (2018a) avaliando a variabilidade espacial da RP verificaram que o uso do valor médio da RP pode levar a resultados errôneos quanto aos procedimentos de manejo do solo, e no caso verificaram que foi superestimado a área com regiões de RP (2000-3000 kPa), e subestimado as áreas com 3000 a 5000 kPa. Cortez et al. (2018b) analisando a variabilidade da RP para tomada de decisão verificaram que se deve evitar o uso de espacialização do RP por médias, e a recomendação de escarificação/subsolagem deve baseada pelo valor máximo de RP do perfil ou da camada de solo e que o uso das ferramentas de agricultura de precisão permitiu verificar a necessidade de realizar a escarificaçã0/subsolagem apenas em parte da área, de forma localizada. Neste aspecto, Cortez et al. (2017) avaliando RP e produtividade em área de plantio direto e escarificado, verificaram que a escarificação reduziu a resistência à penetração permitindo a maior produtividade da soja.

OBJETIVOS

Assim, objetivou-se avaliar a variabilidade espacial da resistência à penetração e da profundidade de ocorrência da resistência máxima em área de cultivo comercial de grãos com sucessão de soja e milho.

MATERIAL E MÉTODOS

O trabalho foi realizado em propriedade comercial do Município de Ponta Porã - MS com área de 135,74 ha. A área é de sucessão de soja e milho segunda safra há mais de 20 anos. O solo da área é classificado como Latossolo Vermelho distrófico, textura argilosa (Santos et al., 2018), com dados médios de argila de 538,75 g kg^{-1} na camada de 0-20 cm. A grade amostral regular para a coleta dos dados foi de 60 pontos, com adição de 11 pontos aleatórios em distâncias diferentes dos pontos regulares (Figura 1). A data de coleta foi em 20/10/2020 com três replicações em torno do ponto central.

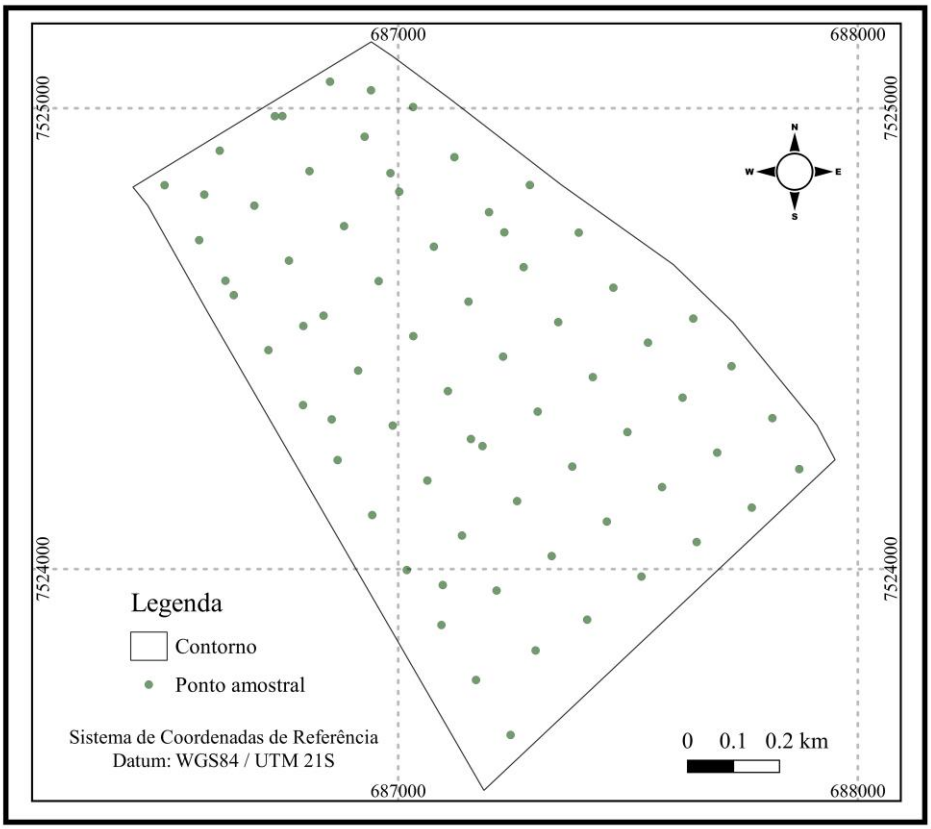


FIGURA 1. Grade amostral utilizada para coleta da resistência do solo à penetração.

A coleta da RP foi realizada com conjunto quadriciclo com amostrador de solo, penetrômetro eletrônico e coletor de dados. O penetrômetro eletrônico utilizado foi o SoloStar (FALKER, 2010), modelo PLG5500, com sistema automatizado para medição da resistência mecânica do solo à penetração, equipado com haste com cone tipo 2, com resolução de coleta de 10 mm e capacidade de armazenamento de 910 medições. O coletor de dados e sistema de navegação (GNSS) em campo utilizado foi o modelo FBX3050, da empresa Falker Automação Agrícola (FALKER, 2013), que serviu para geração do contorno da área, confecção da grade amostral e navegação para a coleta de dados com o conjunto. Coletou-se dados até a profundidade de 0,40 m, sendo avaliado a cada 0,10 m, ou seja, as camadas de avaliação foram de: 0,00-0,10; 0,10-0,20; 0,20-0,30; 0,30-0,40 m além da RP média da profundidade avaliada, a RP máxima da camada 0-0,40 m perfil e a profundidade da RP máxima em cada ponto. A RP máxima média (RPMax média) foi obtida da média das três repetições de cada ponto de coleta. A RP máxima do ponto central (RPMax ponto) foi obtida do maior valor

RESULTADOS E DISCUSSÃO

Os dados médios de umidade do solo foram: 21,80% na camada de 0,0 - 0,10 m; 21,53% na camada de 0,10 - 0,20 m; 22,91% na camada de 0,20 - 0,30 m; 24,01% na camada de 0,30 - 0,40 m indicando que o solo estava abaixo da capacidade de campo, situação recomendada para análise da resistência e inferência sobre a compactação do solo. Os dados da estatística descritiva da RP (Tabela 1), indicam que a média foi baixa em todas as camadas, não chegando nos valores de referência como limitantes ao desenvolvimento radicular como citado por Moraes et al., (2014) de 3,5 MPa (3500 KPa) para área em plantio direto. Já segundo Ribeiro (2010), os limites de RP ocorrem quando: sem compactação (0-2 MPa), compactação tolerável (2-4 MPa), compactado (> 4,0 MPa) e muito compactado (> 6,0 MPa). Assim, os dados médios de RP se mantiveram com valores de compactação tolerável (2-4 MPa), segundo Ribeiro (2010).

TABELA 1. Resultado das análises descritiva para os dados de resistência do solo à penetração.

	Camadas			
Parâmetros	0 a 10 cm	12,5 a 20 cm	22,5 a 30 cm	32,5 a 40 cm
Média (KPa)	866,72	2489,88	2234,70	1952,93
Desvio padrão (KPa)	76,81	82,15	86,86	69,94

Os dados de RP máxima média (RPMax média), RP máxima do ponto (RPMax ponto) e profundidade da RPMax média e ponto (Tabela 2), indicam que a RPMax ponto está acima dos valores citados como crítico para as áreas de plantio direto (Moraes et al., 2014). A RPMax média, obtida da média das três replicações, manteve os valores abaixo do crítico conforme Ribeiro (2010) e Moraes et al. (2014). Esse fato mostra que analisar a RP pela média da área, pode ser equivocado, pois esconde o valor máximo de ocorrência da resistência à penetração no solo e a sua profundidade. Impedindo assim a confecção de mapas que demonstrem os valores máximo de RP e a sua profundidade.

TABELA 2. Resultado das análises descritiva para os dados de resistência do solo à penetração média e máxima do ponto de coleta, como a profundidade média e máxima de ocorrência.

Camada	RPMax média	RPMAX ponto	PROF RPMax média	PROF RPMax ponto
Média (KPa)	3098,46	3603,11	18,37	17,17
Desvio padrão (KPa)	161,13	147,04	0,94	1,72

Os dados da geoestatística processados no SAGA (CONRAD et al., 2015) indicam um ajuste ao modelo esférico para todas as camadas analisadas. O efeito pepita variou bastante entre as camadas da RP de 32000 a 390000. O alcance variou nas camadas, sendo menor nas camadas mais superficiais 0-10 e 10-20 cm (160-180 m), fato este associado a maior mobilização do solo pelas operações de semeadura. As camadas mais profundas (>20 cm), tiveram alcance de 300 m.

TABELA 3. Resultado dos parâmetros da geoestatística feito pelo SAGA com o modelo esférico.

Camada (cm)	Efeito pepita	Alcance (m)
0-10	60000	160
10 a 20,0	90000	180
20 a 30,0	32000	300
30 a 40,0	32000	300
RPmax média	80000	300
RPmax ponto	390000	300
PROFRPmax média	8	300
PROFRPmax ponto	24	300

Os resultados da interpolação das camadas avaliadas mostram que a camada de 0-10 cm e de 30-40 cm apresentaram maior variabilidade espacial (Figura 2). Individualmente a camada de 0-10 cm (Figura 2a) apresentou o menor valor de RP, tendo a maior parte da área na menor classe (0-1000

kPa); na camada de 10-20 cm (Figura 2b) e 20-30 cm (Figura 2c) mostraram mapas uniformes com valores de RP variando na classe 3 (2000-3500 kPa); e na camada de 30-40 cm (Figura 2d) verifica-se redução nos valores de RP, ficando parte da área nas classes dois e três, esse fato demonstra que a concentração da compactação em áreas de plantio direto se concentram de 20-40 cm. Com os valores médios de RP, todas as camadas ficaram dentro do limite aceitável de RP, conforme Moraes et al., (2014) de até 3500 kPa.

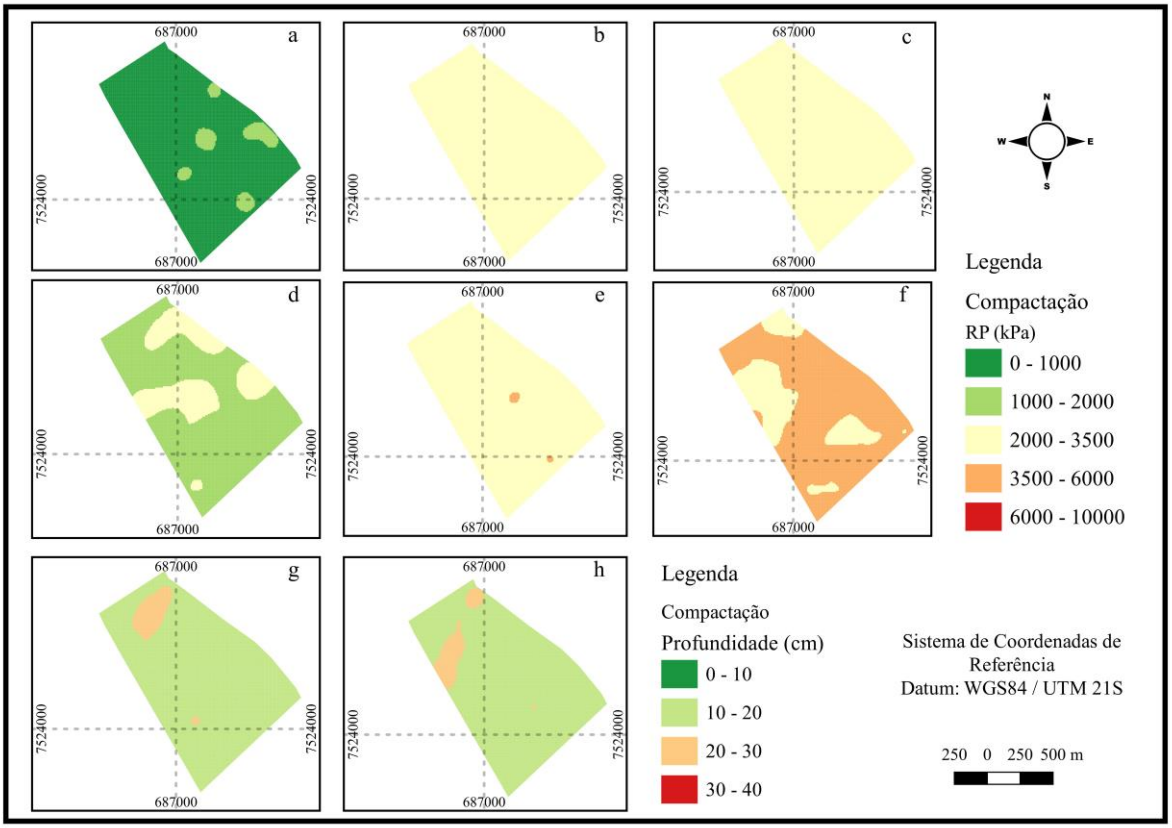


FIGURA 2. Espacialização da resistência a penetração (RP) com base em Moraes et al. (2014) e da profundidade de ocorrência. a: 0-0,10 cm; b: 10-20 cm; c: 20-30 cm; d: 30-40 cm; e: RP máxima média; f: RP máxima ponto; g: profundidade da RP máxima média; h: profundidade da RP máxima do ponto.

O mapa da RP máxima média (Figura 2e) apresentou manchas com RP de 3500-6000 kPa, mas a maior parte da área ficou na classe 3 (2000-3500 kPa). Já na RP máxima do ponto (Figura 2f) verificou-se maior parte da área na classe quatro, com valores de 3500-6000 kPa. Utilizando-se a média da profundidade de ocorrência da RP máxima das três replicações por ponto (Figura 2g), verifica-se que a porção norte apresenta compactação na camada de 20-30 cm. Quando se analisou a profundidade que apresenta o valor máximo da RP entre as três replicações (Figura 2h) verifica-se que a região norte se manteve com presença de compactação na camada de 20-30 cm. Assim, confirma-se a necessidade de uso da RP máxima do ponto e da profundidade desta, para a análise do estado de compactação do solo, como citado por Cortez et al. (2018a, 2018b).

CONCLUSÃO

Ocorre variabilidade espacial da resistência do solo à penetração (RP) principalmente nas camadas de 0,0-10 e 30-40 cm. Os valores médios de RP ficaram abaixo do limite critico de 3500 kPa. No entanto, o valor máximo da RP nos pontos indicou que a maior parte área apresentou compactação entre 3500-6000 kPa, acima do limite, necessitando de processo de remoção da camada compactada,

sendo a maior parte da área essa compactação estava de 10-20 cm. Portanto, o uso do valor médio da RP pode levar a erro de interpretação do real estado de compactação do solo, devendo ser utilizado o valor máximo do ponto e sua profundidade.

AGRADECIMENTOS

A CAPES pela bolsa de Doutorado da segunda autora.

REFERÊNCIAS

CONRAD, O.; BECHTEL, B.; BOCK, M.; DIETRICH, H.; FISCHER, E.; GERLITZ, L.; WEHBERG, J.; WICHMANN, V.; AND BÖHNER, J. System for Automated Geoscientific Analyses (SAGA) v. 2.1.4. **Geosci. Model Dev.,** 8, 1991-2007, 2015.

CORTEZ, J. W.; MATOS, W. P. da S.; ARCOVERDE, S. N. S. Spatial variability of soil resistance to penetration in no tillage system. **Engenharia Agrícola**, v. 5, p. 697-704, 2018a.

CORTEZ, J. W.; CAVASSINI, V. H.; MOTOMIYA, A. V. de A. Spatialization of soil resistance to penetration for localized management by precision agriculture tools. **Engenharia Agrícola**, v. 5, p. 690-696, 2018b.

CORTEZ, J. W.; MAUAD, M.; SOUZA, L. C. F. de. Agronomical attributes of soybeans and soil resistance to penetration in no-tillage and chiseled surfaces. **Engenharia Agrícola**, v. 37, n. 1, p. 98-105, 2017.

FALKER Automação Agrícola. **SoloStar**. Porto Alegre: Falker, 2010. 7p.

FALKER Automação Agrícola. **Manual: coletor de dados e navegação em campo**. Porto Alegre: Falker, 2013. 31p.

MORAES, M. T.; DEBIASI, H.; CARLESSO, R.; FRANCHINI, J. C.; SILVA, V. R. Critical limits of soil penetration resistance in a rhodic Eutrudox. **Revista Brasileira de Ciência do Solo**, v.38, n.1, p.288- 298, 2014.

QGIS.org. **QGIS Geographic Information System**. QGIS Association. 2022. Disponível em: http://www.qgis.org Acesso em: 03 de fevereiro de 2022.

RIBEIRO, C. A. **Variabilidade espacial da resistência mecânica do solo à penetração em áreas mecanizadas de cana-de-açúcar (Saccharum officinarum).** Jaboticabal: FCAV/UEP: 2010. 85p. Dissertação Mestrado.

SANTOS, H.G.; JACOMINE, P.K.T.; ANJOS, L.H.C.; OLIVEIRA, V.A.; LUMBRERAS, J.F.; COELHO, M.R.; ALMEIDA, J.A.; ARAÚJO, J.C.; OLIVEIRA, J.B.; CUNHA, T.J.F. **Sistema Brasileiro de Classificação de Solos**. 5. ed. Brasília, DF: Embrapa, 2018. 356 p.

É VIÁVEL DEMARCAR ZONAS DE CARBONO ORGÂNICO DO SOLO COM BASE EM DADOS DIGITAIS?

LUIZ GUSTAVO DE GÓES STERLE [1]; RICARDO CANAL FILHO [2]; EUDOCIO RAFAEL OTÁVIO DA SILVA [2]; MARCELO CHAN FU WEI [2]; JOSÉ PAULO MOLIN [3]

[1]Mestrando. Av. Pádua Dias, 11 - Agronomia, Piracicaba - SP, 13418-900. Escola Superior de Agricultura 'Luiz de Queiroz; [2]Doutorando. Av. Pádua Dias, 11 - Agronomia, Piracicaba - SP, 13418-900. Escola Superior de Agricultura 'Luiz de Queiroz; [3]Professor. Av. Pádua Dias, 11 - Agronomia, Piracicaba - SP, 13418-900. Escola Superior de Agricultura 'Luiz de Queiroz

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

O carbono orgânico do solo (COS) é importante para diversos serviços ecossistémicos. Logo, é relevante compreender sua distribuição espacial e temporal para fins de agricultura, manejo e conservação. As zonas, definidas como sub-regiões de uma área, distintas entre si e com características semelhantes, e são geridas de maneira uniforme dentro de cada zona. O objetivo do trabalho foi avaliar a utilização de camadas de dados digitais como variáveis para delineamento dessas zonas com foco em teores de COS. Dados de uma microbacia hidrográfica foram obtidos a partir de mapeamento digital de solo e submetidos às análises estatísticas descritivas, correlação, geoestatística e componentes principais (PCA). Para delinear as zonas, os componentes principais (PCs) foram agrupados utilizando o método Fuzzy C-Means. O número ótimo de zonas foi obtido a partir dos índices Fuzzy Performance Index (FPI) e Normalized Classification Entropy (NCE). Quatro PCs foram necessários para explicar 80% da variabilidade do COS e, de acordo com os índices, o número ótimo de zonas correspondeu a cinco. Foi observado que a zona 1 possui os maiores teores de COS e as zonas 3 e 4, os menores, com teores médios de 13,5 g kg-1 e 10,6 g kg-1, respectivamente. A utilização de camadas de dados digitais como variáveis para delineamento de zonas com foco em teores de COS apresenta-se como opção para o desenvolvimento de técnicas especificas de manejo do COS apropriadas para cada zona.

PALAVRAS-CHAVE: Sensoriamento remoto; geoestatística; estatística multivariada

ABSTRACT

Soil organic carbon (SOC) is important for various ecosystem services. Therefore, it is essential to understand its spatial and temporal distribution for agriculture, management, and conservation purposes. Zones, defined as sub-regions of an area that are distinct from each other with similar characteristics, are managed uniformly within each zone. The aim of this study was to evaluate the use of digital data layers as variables for delineating these zones, with a focus on SOC levels. Data from a watershed were obtained through digital soil mapping and subjected to descriptive statistical analysis, correlation, geostatistics, and principal component analysis (PCA). To delineate the zones, the principal components (PCs) were grouped using the Fuzzy C-Means method. The optimal number of zones was determined using the Fuzzy Performance Index (FPI) and Normalized Classification Entropy (NCE) indices. Four PCs were required to explain 80% of SOC variability, and according to the indices, the optimal number of zones was five. It was observed that zone 1 had the highest SOC levels, while zones 3 and 4 had the lowest, with average levels of 13.5 g kg-1 and 10.6 g kg-1, respectively. The use of digital data layers as variables for delineating zones based on SOC levels appears to be a viable option for the development of specific SOC management techniques appropriate for each zone.

KEYWORDS: Remote sensing; geostatistics; multivariate statistics

INTRODUÇÃO

O carbono orgânico do solo (COS) é importante para diversos serviços ecossistémicos, que incluem a recuperação e manutenção da saúde e qualidade do solo, a redução dos impactos das mudanças climáticas, fertilidade do solo e produção de alimentos (WANG et al., 2013). O conteúdo de COS é influenciado por diversos fatores que variam significativamente em um contexto espaço-temporal da natureza, incluindo o clima, a vegetação, características do solo, regimes de água do solo, uso da terra, topografia e tipo de manejo (DHARUMARAJAN et al., 2021). Logo, é relevante compreender a distribuição espacial e temporal do COS para entender o impacto do manejo nos solos (BONETTI et al., 2019), e, para isto, são frequentemente usadas técnicas de interpolação a partir de amostras (REZA et al., 2019). No entanto, a coleta de amostras de campo e a análise laboratorial são onerosas e custosas, o que dificulta o monitoramento contínuo, especialmente em grande escala (ROSSEL e MCBRATNEY, 1998; ZHAO et al. 2020), tornando-se necessário técnicas alternativas de avaliação que sejam rápidas e de baixo custo para o monitoramento do COS (GHOLIZADEH et al., 2021). Neste contexto, a modelagem empírica baseada em métodos matemáticos e estatísticos, como mapeamento digital do solo (DSM), que leva em conta fatores antropogênicos e ambientais para a previsão do COS, é uma hipótese e apresenta-se como opção mais realista do que as técnicas de interpolação geoestatística, sendo já conhecida e utilizada para predição de dados espaciais do solo (DHARUMARAJAN et al., 2021). Dessa forma, o delineamento de zonas de COS utilizando DSM não apenas impulsionará a gestão específica de carbono de forma sustentável, mas também ajudará a identificar áreas para melhores serviços ecossistêmicos, como produção de alimentos, saúde do solo, neutralidade da degradação e resiliência climática. (DARIPA et al., 2022).

OBJETIVOS

O objetivo do trabalho foi avaliar a utilização de camadas de dados digitais como variáveis para delineamento de zonas com foco em teores de COS.

MATERIAL E MÉTODOS

A área de estudo está localizada na transição entre os biomas Amazônia e Cerrado. O estudo considerou a área da microbacia hidrográfica do alto Juruena, no estado do Mato Grosso, totalizando 93.810 km² (Figura 1).

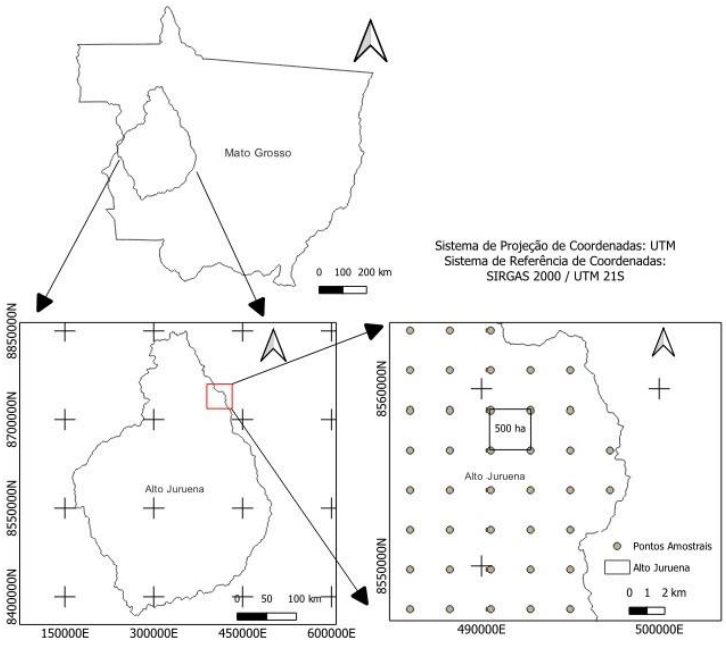


FIGURA 1. Localização da área de estudo e densidade amostral.

Dados de DSM (teores de argila, silte e areia; água disponível (AD); densidade aparente do solo (DA); Capacidade de Troca Catiônica (CTC); mapa de condutividade elétrica do solo (CE); pH em água e COS), média dos valores do Índice de Vegetação da Diferença Normalizada (NDVI) de oito anos (2016-2023), elevação e dados climáticos (amplitude térmica; precipitação; temperatura mínima, média e máxima e umidade relativa) foram utilizados como variáveis nesta abordagem (Tabela 1).

TABELA 1. Camadas de informação utilizadas.

Camada	Fonte	Resolução	Referência
AD (mm cm^{-1})	DSM	90 m	VASQUES et al. 2021
DA (Mg m^{-3})	DSM	90 m	VASQUES et al. 2021
Argila (g kg^{-1})	DSM	90 m	VASQUES et al. 2021
CTC (cmolc dm^{-3})	DSM	90 m	VASQUES et al. 2021
CE (mS m^{-1})	DSM	90 m	VASQUES et al. 2021
pH	DSM	90 m	VASQUES et al. 2021
Areia (g kg^{-1})	DSM	90 m	VASQUES et al. 2021
Silte (g kg^{-1})	DSM	90 m	VASQUES et al. 2021
COS (g kg^{-1})	DSM	90 m	VASQUES et al. 2021
Elevação (m)	SRTM DEM	30 m	EROS, 2018
NDVI	Sentinel-2 MSI	90 m	ESA, 2024
Precipitação (mm)	NASA Power	55,66 x 69,57 km (lat x long)	NASA, 2020
Amplitude Térmica (T°C)	NASA Power	55,66 x 69,57 km (lat x long)	NASA, 2020
Temperatura Máxima (T°C)	NASA Power	55,66 x 69,57 km (lat x long)	NASA, 2020
Temperatura Média (T°C)	NASA Power	55,66 x 69,57 km (lat x long)	NASA, 2020
Temperatura Mínima (T°C)	NASA Power	55,66 x 69,57 km (lat x long)	NASA, 2020
Umidade Relativa (%)	NASA Power	55,66 x 69,57 km (lat x long)	NASA, 2020

*(lat x long): latitude x longitude

O tamanho do pixel usado foi de 500 ha, para manter a resolução espacial dos pontos utilizados para realizar a amostragem dos demais atributos analisados neste estudo (Figura 1). A média anual dos atributos climáticos para cada ponto foi calculada e submetidas à análise geoestatística e interpolação por krigagem ordinária, sendo posteriormente transformados em raster. Analisou-se a série histórica de 1981 a 2020, em uma área maior do que a bacia do alto Juruena, que totaliza 342.376 km², correspondendo a 121 pontos. A análise geoestatística foi realizada através do complemento Smart-map do QGIS (WILLAM, 2024). Para cada variável, foi feito o ajuste do semivariograma teórico e determinado o modelo (linear, esférico, exponencial e gaussiano) de melhor ajuste baseado nos parâmetros do variograma (efeito pepita, componente estrutural, patamar e alcance) e validação

cruzada, selecionado pelo maior valor de coeficiente de determinação (R^2) e menor valor de Raiz Do Erro Quadrático Médio (RMSE) (Tabela 2).

A correlação de Spearman avalia a intensidade e o sentido da relação monótona entre duas variáveis que estejam no mínimo numa escala ordinal. Tem em consideração as ordens atribuídas às observações, em vez dos valores originais, e pode ser aplicado tanto no caso de dados lineares como no caso de dados não lineares (SOUSA, 2019). Rumsey (2023) traz a seguinte sugestão de tamanhos de efeito para coeficientes de correlação de Spearman (rs): rs = (±1): relação linear perfeita; rs = (±0,70): relação linear forte; rs = (±0,50): relação linear moderada; rs = (±0,30): relação linear fraca; rs = 0: ausência de relação linear. A análise dos componentes principais (PCA) é uma técnica estatística multivariada que visa redução de dimensionalidade, transformando um conjunto de variáveis originais em outro conjunto de variáveis de mesma dimensão, denominadas de componentes principais (PCs). Esses PCs possuem propriedades importantes: cada PC é uma combinação linear de todas as variáveis originais, são independentes entre si e são estimados com o propósito de reter, em ordem de estimação, o máximo de informação em termos da variação total contida nos dados (HONGYU, 2015). O Fuzzy Performance Index (FPI) e o Normalized Classification Entropy (NCE) são dois índices usados para avaliar a qualidade dos agrupamentos gerados, especialmente em algoritmos como o Fuzzy C-Means (FCM). Ambos os índices ajudam a determinar o número ótimo de agrupamentos em um conjunto de dados (DARIPA et al., 2022). A variabilidade dos teores de COS (g kg^{-1}) dentro de cada zona foi realizada conforme descrito por Wilding (1985): alta variabilidade (CV > 35%); média variabilidade (CV de 15% a 35%); baixa variabilidade (CV < 15%). A análise de variância das médias de COS foi conduzida entre as diferentes zonas, aplicando o teste de Tukey a 5% de significância.

RESULTADOS E DISCUSSÃO

TABELA 2. Parâmetros de ajuste do semivariograma teórico para interpolação

Atributo	Modelo	Max_dist (m)	lag	C0	C0 + C1	a (m)	RMSE	R^2
Amplitude Térmica	Linear com patamar	400000	55290	0.00	2.92	392031	0.92	0.89
Precipitação	Linear com patamar	400000	55290	0.00	0.30	392031	0.00	0.96
T°C Máx	Gaussiano	400000	55290	0.02	1.29	245774	0.01	0.99
T°C Média	Gaussiano	400000	55290	0.00	0.51	221634	0.00	0.99
T°C Min	Linear com patamar	400000	55290	0.00	1.52	392031	0.16	0.93
Umidade R.	Linear com patamar	400000	55290	0.00	16.30	392031	15.83	0.93

*Max_dist: Máxima distância; C0: Efeito pepita; C0 + C1: Patamar; a: Alcance; RMSE: Raiz do erro quadrático médio; R^2: Coeficiente de determinação

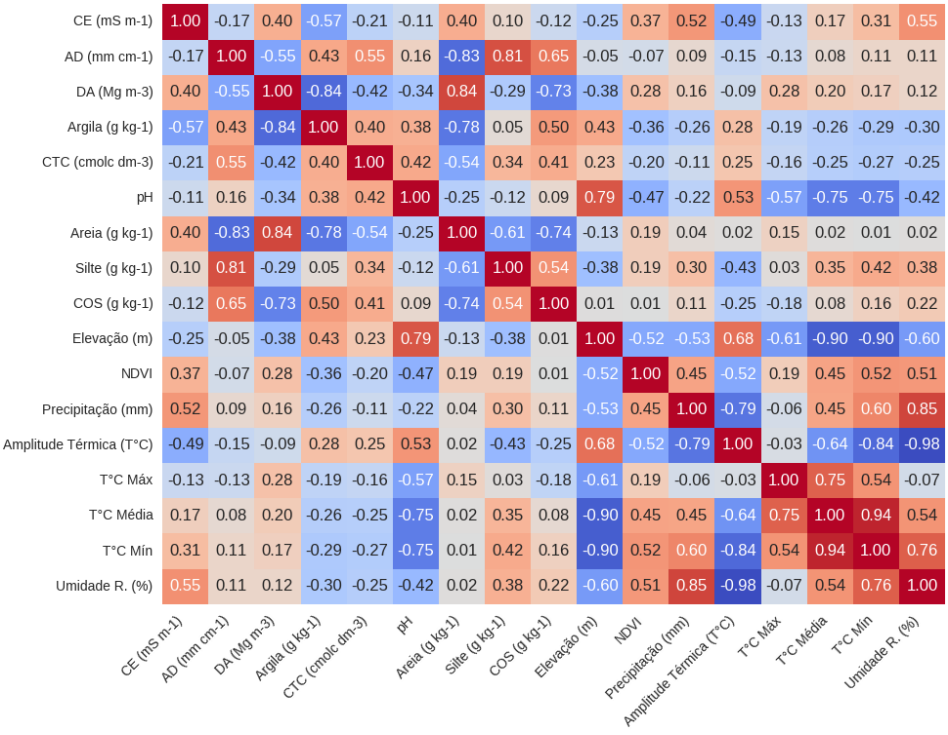


FIGURA 2. Matriz de correlação de Spearman.

Os atributos que merecem destaque quanto sua correlação com COS são: AD (0,65), DA (-0,73) e areia (-0,74) (Figura 2). Estes dados corroboram com Bonetti et al. (2019), os autores destacam a importância do COS principalmente em solos arenosos, onde a matéria orgânica é responsável pela maior parte da retenção de água e nutrientes.

Quatro componentes explicam pelo menos 80% da variância. A variância explicada pelos PCs foram: PC 1: 40,0%; PC 2: 26,7%; PC 3: 12,6%; PC 4: 5,7%. Além disso o gráfico da esquerda apresenta a contribuição de cada atributo em diferentes PCs (Figura 3).

Cinco foi o número ótimo de zonas, de acordo com os índices FPI (0,48) e NCE (0,21) (Figura 3). Foi observado que a zona 1 possui os maiores teores de carbono orgânico do solo e as zonas 3 e 4, os menores, com teores médios de 13,5 g kg-1 e 10,6 g kg-1, respectivamente (Figura 4), os valores médios das zonas foram comparados e constam na tabela 3. O Coeficiente de Variação (CV) foi destacado como particularmente crucial para descrever a variabilidade dos atributos do solo, como o COS (REZA et al., 2021). Os valores de CV de COS encontrados foram: zona 1: CV = 11,0% - baixa variabilidade; zona 2: CV = 9.0% - baixa variabilidade; zona 3: CV = 9.5% - baixa variabilidade; zona 4: CV = 8.1% - baixa variabilidade; zona 5: 13.8% - baixa variabilidade.

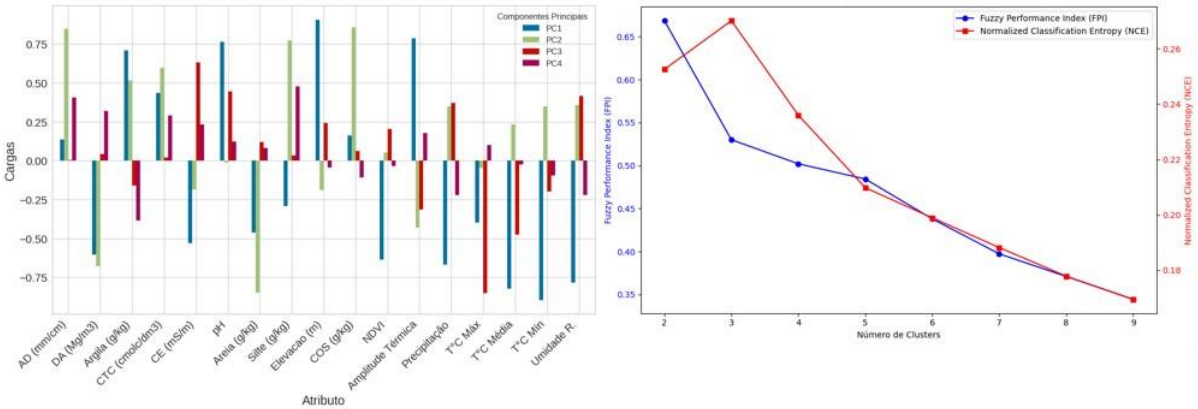


FIGURA 3. Contribuição componentes principais (PCA) e índices de número ótimo de agrupamento.

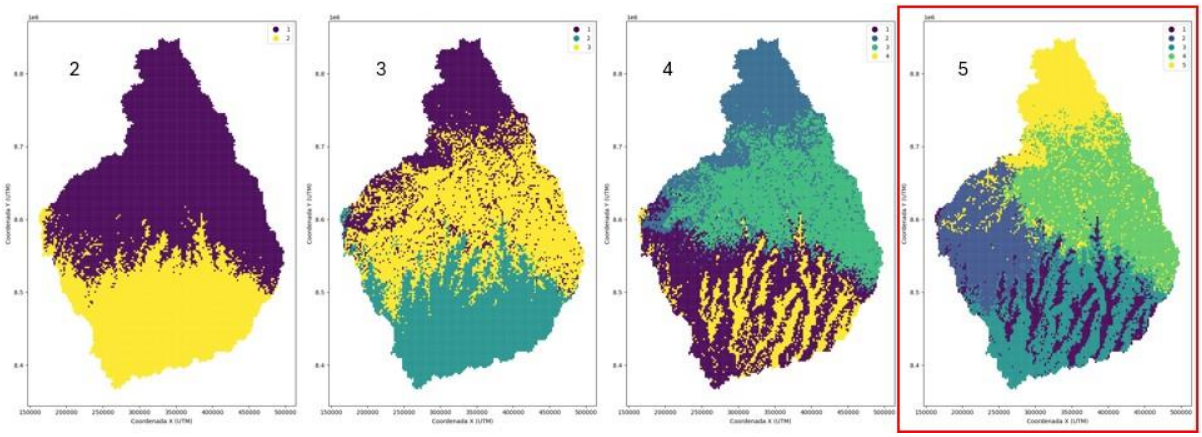


FIGURA 4. Mapa de dispersão com diferentes números de zonas. O mapa destacado em vermelho indica o número ideal de cinco zonas.

TABELA 3. Resultados do teste de comparação dos teores médios de COS entre zonas.

Zonas	MÉDIAS (g kg^{-1})	Resultados do teste
4	10.6	A
3	10.6	A
2	11	B
5	13.1	C
1	13.5	D

*Médias seguidas pela mesma letra não difere entre si teste de Tukey, ao nível de significância de 5%.

CONCLUSÃO

A utilização de camadas de dados digitais como variáveis para delineamento de zonas com foco em teores de COS apresenta-se como opção para o desenvolvimento de técnicas especificas de manejo do COS apropriadas para cada zona, que podem melhorar os serviços ecossistêmicos e alcançar os objetivos de mitigação das mudanças climáticas.

REFERÊNCIAS

BONETTI, J. A.; ANGHINONI, I.; GUBIANI, P. I.; CECAGNO, D.; MORAES, M. T. de. Impact of a long-term crop-livestock system on the physical and hydraulic properties of an Oxisol. **Soil and Tillage Research**, v. 186, p. 280-291, 2019. ISSN 0167-1987.

DARIPA, A.; CHATTARAJ, S.; MALAV, L.; RAY, P.; SHARMA, R.; MOHEKAR, D. S.; RAMAMURTHY, V.; RAGHUVANSHI, M. S.; PATIL, N. G. Risk assessment of agricultural soils surrounding an iron ore mine: A field study from Western Ghat of Goa, India. **Soil and Sediment Contamination**, v. 32, p. 570-590, 2022.

DHARUMARAJAN, S.; KALAISELVI, B.; SUPUTHRA, A.; LALITHA, M.; VASUNDHARA, R.; ANIL KUMAR, K. S.; NAIR, K. M.; HEGDE, R.; SINGH, S. K.; LAGACHERIE, P. Digital soil mapping of soil organic carbon stocks in Western Ghats, South India. **Geoderma Regional**, v. 25, e00387, 2021.

ESA, EUROPEAN SPACE AGENCY. **Sentinel-2 Mission**. Disponível em: https://sentiwiki.copernicus.eu/web/s2-mission#MSI-Instru. Acesso em: 07 ago. 2024.

GHOLIZADEH, A.; VISCARRA ROSSEL, R. A.; SABERIOON, M.; BOR?VKA, L.; KRATINA, J.; PAVL?, L. National-scale spectroscopic assessment of soil organic carbon in forests of the Czech Republic. **Geoderma**, v. 385, p. 114832, 2021.

HONGYU, K.; SANDANIELO, V. L. M.; OLIVEIRA JUNIOR, G. J. Análise de Componentes Principais: resumo teórico, aplicação e interpretação. **E&S - Engineering and Science**, v. 5, n. 1, p. 83, 2015.

NASA POWER. **Methodology for Meteorology**, 2020. Disponível em: https://power.larc.nasa.gov/docs/methodology/meteorology/. Acesso em: 15 ago. 2024.

REZA, S. K.; KUMAR, N.; RAMACHANDRAN, S.; MUKHOPADHYAY, S.; SINGH, S. K.; DWIVEDI, B. S.; RAY, S. K. Geo-spatial analysis for horizontal and vertical variability of bulk density, particle-size distribution and soil moisture content in Tripura, northeastern India. **Arabian Journal of Geosciences**, v. 14, p. 2734, 2021.

REZA, S. K.; RAY, P.; RAMACHANDRAN, S.; BANDYOPADHYAY, S.; MUKHOPADHYAY, S.; SAH, K. D.; NAYAK, D. C.; SINGH, S. K.; RAY, S. K. Profile distribution of soil organic carbon in major land use systems in Bishalgarh block, Tripura. **Journal of the Indian Society of Soil Science**, v. 67, p. 236-239, 2019.

RUMSEY, D. J. What is r value correlation? **Dummies**, 6 fev. 2023. Disponível em: https://www.dummies.com/article/academics-the-arts/math/statistics/how-to-interpret-a-correlation-coefficient-r-169792/. Acesso em: 15 ago. 2024.

SOUSA, Á. Coeficiente de correlação de Pearson e coeficiente de correlação de Spearman: O que medem e em que situações devem ser utilizados? **Correio dos Açores: Matemática**, p. 19, 2019.

USGS EROS Archive - Digital Elevation - Shuttle Radar Topography Mission (SRTM) 1 Arc-Second Global. U.S. **Geological Survey**, 2018.W Disponível em: https://www.usgs.gov/centers/eros/science/usgs-eros-archive-digital-elevation-shuttle-radar-topography-mission-srtm-1?qt-science_center_objects=0#qt-science_center_objects. Acesso em: 04 ago. 2024.

VASQUES, G. M.; COELHO, M. R.; DART, R. O.; CINTRA, L. C.; BACA, J. F. M.; MENDONÇA-SANTOS, M. L. Soil Organic Carbon Content Maps for Brazil at 0-5, 5-15, 15-30, 30-60, 60-100 and 100-200 cm Depth Intervals with 90 m Spatial Resolution. Version 2021. **Embrapa Solos**, Rio de Janeiro, Brazil, 2021.

VISCARRA ROSSEL, R. A.; McBRATNEY, A. B. Laboratory evaluation of a proximal sensing technique for simultaneous measurement of soil clay and water content. **Geoderma**, v. 85, n. 1, p. 19-39, 1998.

WANG, Zhi-Ping; HAN, Xing-Guo; CHANG, Scott X.; WANG, Bin; YU, Qiang; HOU, Long-Yu; LI, Ling-Hao. Soil organic and inorganic carbon contents under various land uses across a transect of continental steppes in Inner Mongolia. **CATENA**, v. 109, p. 110-117, 2013.

WILDING, L. P. Spatial variability: its documentation, accommodation, and implication to soil surveys. In: NIELSEN, D. R.; BOUMA, J. (Eds.). **Soil spatial variability**. Wageningen: Pudoc, p. 166-194, 1985.

WILLAM, G. **SmartMapPlugin**. GitHub, [S.l.], [s.d.]. Disponível em: https://github.com/gustavowillam/SmartMapPlugin. Acesso em: 08 ago. 2024.

ZHAO, X.; ARSHAD, M.; LI, N.; ZARE, E.; TRIANTAFILIS, J. Determination of the optimal mathematical model, sample size, digital data and transect spacing to map CEC (Cation exchange capacity) in a sugarcane field. **Computers and Electronics in Agriculture**, v. 173, p. 105436, 2020.

UM ESTUDO DE CASO SOBRE EXPERIMENTAÇÃO ON FARM PARA AVALIAÇÃO DE POPULAÇÕES DE PLANTAS DE SOJA COM USO DOS RECURSOS DISPONÍVEIS NA FAZENDA

MARCELLO RODRIGUES ALVES FRANCHI [1]; ISRAEL MOLINA CYRINEU [2]; FABIO KAGAMI TAIRA [3]; LUCAS HUNHOFF [4]; LEANDRO MARIA GIMENEZ [5]

[1]Pesquisador. Rondonópolis - MT. GeoMec Pesquisa e Consultoria Agrícola; [2]Doutorando. Stillwater, OK - E.U.A.. Oklahoma State University; [3]Encarregado de Mecanização e AP. Primavera do Leste - MT. Grupo Carlos Alberto Polato; [4]Consultor. Rondonópolis - MT. GeoMec Pesquisa e Consultoria Agrícola; [5]Professor Doutor. Piracicaba - SP. Escola Superior de Agricultura Luiz de Queiroz, ESALQ

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Para obter produtividades elevadas na cultura da soja (*Glycine max* [L.] Merr.) é necessário que a população de plantas seja corretamente definida. Os ambientes de produção diferem espacialmente e as empresas detentoras das cultivares sugerem populações de plantas por macrorregiões e em faixas amplas. Refinamentos das épocas e populações de plantas são realizadas por meio de testes em muitas propriedades, muitas vezes de forma onerosa e por vezes pouco representativas da maior parte dos campos. As ferramentas para manejo da variabilidade espacial são meios para conduzir experimentos mais adequados, contemplando a variabilidade local. O estudo de caso foi desenvolvido em uma área comercial de produção de soja, no estado de Mato Grosso que apresenta variabilidade na composição granulométrica. Foram avaliadas 5 populações de plantas (200, 244, 289, 333 e 378 mil sementes ha^{-1}) em três regiões. Avaliou-se os efeitos das variáveis sobre o vigor de plantas e produtividade da soja. O ano foi considerado ótimo em termos de condições climáticas. Como resultados obteve-se diferenças no vigor, não ocorrendo diferença na produtividade da soja que em média foi de 3,8 Mg ha^{-1}. Como desdobramento de manejo ficou demonstrado que poderia ter sido utilizada uma população menor que a padrão da propriedade e em taxa única.

PALAVRAS-CHAVE: Taxa de semeadura; físiologia vegetal; variabilidade espacial

ABSTRACT

To achieve high yields in soybean (*Glycine max* [L.] Merr.) cultivation, it is necessary to correctly define the plant population. Production environments vary spatially, and seed companies suggest plant populations for macroregions thus on broad ranges. Refinements in planting times and populations are done through tests on plots or strips on farm, often costly and sometimes not representative for most fields. Spatial variability management tools are means to conduct more suitable experiments, addressing local variability. A case study was conducted in a commercial soybean production area in Mato Grosso state, which presents variability in soil composition. Five plant populations (200, 244, 289, 333, and 378 thousand seeds ha^{-1}) were evaluated in three regions. The effects of variables on plant vigour and soybean productivity were assessed. The year was considered optimal in terms of weather conditions. Results showed differences in vigour, but no difference in soybean productivity, which averaged 3,8 Mg ha^{-1}. As a management outcome, it was demonstrated that a lower population than the standard of the property could have been used at a single rate.

KEYWORDS: ;

INTRODUÇÃO

A otimização do manejo das lavouras por meio de técnicas que considerem a variabilidade espacial dos fatores de produção vem sendo relatada há décadas na literatura (ROBERT, 1993). A experimentação "on farm" é uma técnica na qual o experimento é realizado considerando a variação espacial presente na área (BULLOCK et al., 2019). Desse modo busca-se contemplar as condições reais da área produtiva, sendo as unidades amostrais distribuídas em zonas distintas, a fim de obter resultados adequados a cada zona de manejo (GREGO et al., 2022). Esta técnica já foi utilizada em sistemas de produção de cana-de-açúcar e algodão, tendo permitido avaliar diferentes taxas de semeadura em áreas com potenciais produtivos distintos e com repetições (GREGO et al., 2022; SPERANZA et al., 2022). A técnica tem potencial para definir a melhor taxa de semeadura localmente.

Em 2022 o produto interno bruto (PIB) da cadeia produtiva da soja cultivada (*Glycine max* [L.] Merr.) arrecadou R$ 671 bilhões para a economia brasileira (CEPEA, 2023). Dentre os estados que produzem soja no Brasil, Mato Grosso se encontra como o maior produtor com 12,1 milhões de hectares cultivados (EMBRAPA, 2023). Para o aumento e manutenção da produtividade é necessário que a população de plantas esteja de acordo com o potencial genético e com o ambiente no qual a soja está sendo cultivada (RIGSBY; BOARD, 2003; VITANTONIO-MAZZINI et al., 2020). Além dos aspectos relacionados ao desempenho agronômico a elevação dos investimentos em sementes e sua correta definição se constitui em oportunidade de redução dos custos de produção (CONAB, 2023b). Na região de Sorriso - MT, o custo médio de sementes representou R$ 721 por hectare, 9,3% das despesas de custeio de produção (CONAB, 2023b), portanto reduções na taxa de semeadura sem prejuízo na produtividade trazem reduções significativas no custo, aumentando o lucro do produtor.

A soja é uma planta com alta plasticidade em sua produção de ramos e hastes, ou seja, redução em população induz uma maior expressão destas características, enquanto nas populações maiores o efeito é inverso (BALBINOT Jr et al., 2018; COX, et al., 2010). Além disso, em diversos ambientes foi reportado que não há perda produtiva em casos de redução da taxa de semeadura (RIGSBY; BOARD, 2003; VITANTONIO-MAZZINI et al., 2020; SILVA, E., et al., 2021). Entretanto, é usual agricultores seguirem recomendações oferecidas por companhias de sementes para estabelecer o estande (SILVA, E., et al., 2022). Sendo assim, ajustes locais das populações de plantas devem ser buscados. Buscando-se avaliar a oportunidade de otimizar a taxa de semeadura um estudo de campo foi conduzido na cidade de Primavera do Leste-MT em uma propriedade agrícola.

OBJETIVOS

Foram implantadas unidades amostrais com cinco populações diferentes em três diferentes zonas de manejo com potenciais produtivos distintos com o objetivo de (i) obter a taxa de semeadura a fim de otimizar a produtividade, e (ii) validar a técnica de experimentação on-farm para este tipo de avaliação.

MATERIAL E MÉTODOS

O experimento foi conduzido em uma propriedade rural na municipalidade de Primavera do Leste-MT (15.23°S, 54.48°L) durante a safra de 2022-2023. A área experimental ocupou 20 hectares dentro de uma gleba com produção comercial. A área é manejada com plantio direto e nos anos anteriores foi cultivada soja na safra principal seguida por milho na segunda safra. A produtividade média da gleba estudada foi de 3,7 Mg ha^{-1} para os últimos quatro anos de cultivo de soja. Foi utilizada uma variedade comercial adaptada para a área e amplamente utilizada na região (DM81i84, GDM®), a semeadura foi realizada no dia 22/10/2022 e a colheita no dia 08/03/2023, totalizando o ciclo com 137 dias. A população padrão adotada pelos técnicos do agricultor na gleba no qual foi realizado o experimento foi de 289 mil sementes ha^{-1}. Segundo o fornecedor da semente, a população indicada para as condições da fazenda era de 250 até 320 mil sementes ha^{-1}. Durante o período do experimento

a precipitação acumulada foi de 1335 mm, dentre os meses de outubro a março, sendo novembro o mês com menor pluviosidade, 85mm, portanto potencialmente não houve estresse hídrico ao longo do ciclo. As parcelas apresentavam 21,6 m de largura e 90,0 m de comprimento, foram implantadas utilizando semeadora Case FastRiser 6148 com 48 linhas de 0,45m de espaçamento entre linhas, com sistema de dosador Precision Planting Vset acionado por motor hidráulico interligado com um mapa de prescrição no monitor AFS Pro 1200 e trator modelo Steiger 540 da marca Case.

A área experimental apresentava três porções com características produtivas e texturais distintas, sendo assim separadas em unidades de manejo diferenciado (baixo potencial produtivo, médio potencial produtivo, e alto potencial produtivo). As porções foram subdivididas por meio de dados de condutividade elétrica, vigor de planta obtido por imagens de satélite e dados de produtividade de anos anteriores. Dentro de cada unidade de manejo, o tratamento de taxa de semeadura foi organizado seguindo delineamento em blocos casualizados com dez replicações por zona de manejo (*n*=50 por zona de manejo). As taxas de semeadura escolhidas foram 200, 244, 289, 333 e 378 mil sementes ha^{-1} (9, 11, 13, 15 e 17 sementes por metro linear respectivamente) (FIGURA 1). Totalizando então 150 parcelas. Com o objetivo de verificação do estande após a emergência, foi realizada a contagem de plantas em posições aleatórias do experimento.

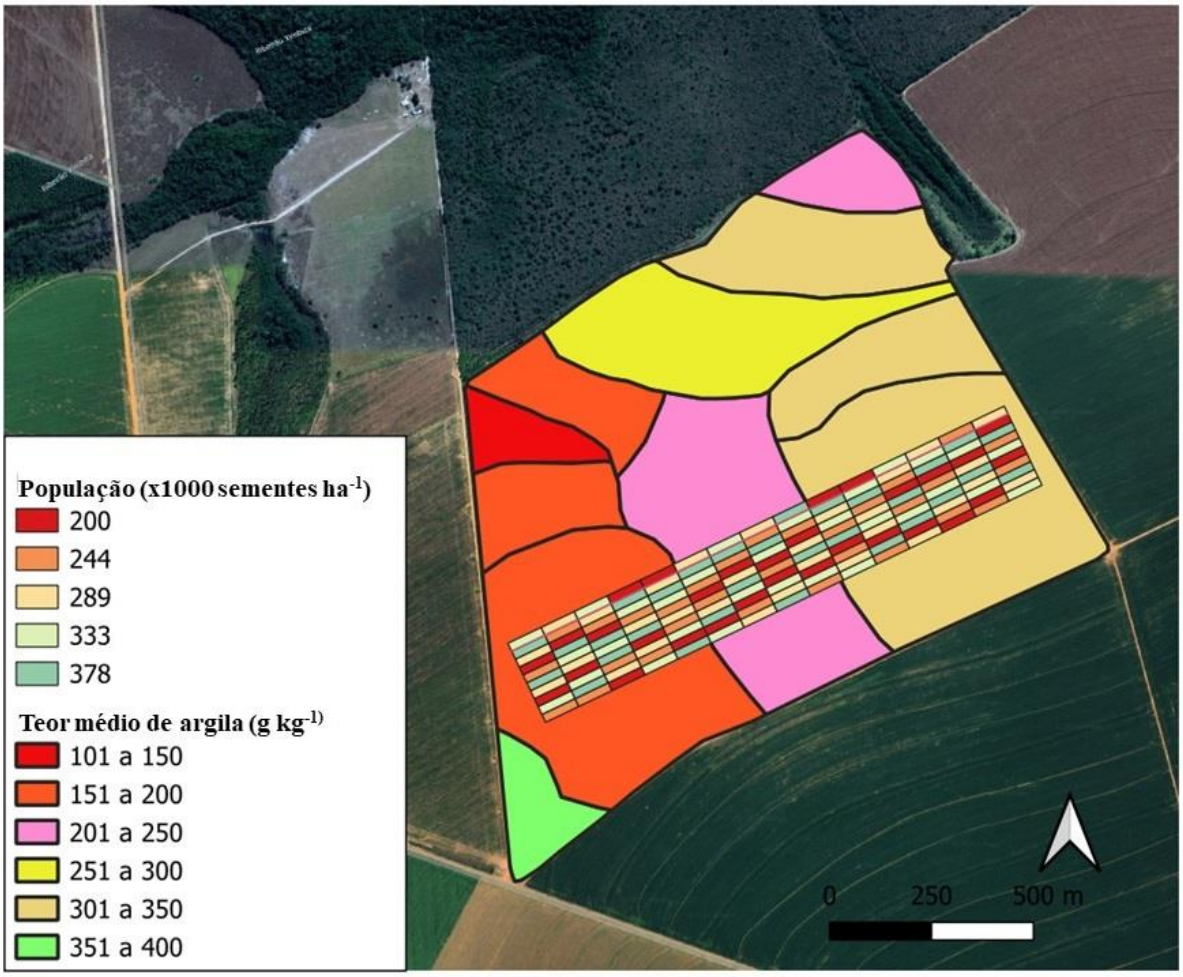


FIGURA 1. Croqui da área experimental apresentando os tratamentos de taxa de semeadura

Os valores de produtividade foram obtidos por meio dos dados de sistemas de mapeamento de presentes nas duas colhedoras que realizaram a colheita. Foram utilizados o modelo CR585 do fabricante New Holland® e o modelo S550 do fabricante John Deere®.

Para os dados oriundos de cada colhedora foi realizada a remoção de dados com produtividade nula, negativa ou acima de três vezes a produtividade máxima esperada para a região (e.g. acima de 20 Mg ha^{-1}), estes valores foram considerados como erros de coleta. Na sequência procedeu-se à remoção de valores considerados discrepantes. Para tal foram removidos valores de produtividade respectivamente superiores e inferiores à média adicionada e subtraída em três desvios padrão. Para eliminar o efeito da calibração das máquinas os valores de produtividade da colhedora que colheu a menor área foram corrigidos para os da outra colhedora. Para tal calculou-se a média de produtividade de passadas lado a lado, das duas colhedoras e por razão simples entre estas médias obteve-se um coeficiente utilizado na correção pelo produto, e.g. os valores de produtividade de cada ponto da colhedora que se desejava corrigir os valores foram multiplicados pelo coeficiente. Posteriormente, foram removidos 10 metros no início e final de cada parcela a fim de eliminar os dados que representam a transição entre os tratamentos, também foi removido os dados com menos de 4 metros de distância lateral entre as parcelas, visto que isso poderia caracterizar colheita com plataforma misturando os tratamentos.

Como forma de realizar uma avaliação indireta sobre produção de biomassa do dossel, foi selecionada uma imagem de satélite da constelação *Planet Scope* durante a fase V5 soja (18/11/2022), com resolução espacial de 3 metros. Foram utilizadas as bandas do vermelho (590-670 nm) e infravermelho próximo (NIR) (780-860nm) a fim de calcular o índice de vegetação por diferença normalizada (NDVI) (e.q 1). Para a análise escolheu-se imagem sem presença de nuvem. Tomou-se o valor médio de cada parcela para realizar a análise estatística. O geoprocessamento foi realizado utilizando sistema de informações geográficas QGIS 3.28.3.

$$NDVI = (Red - NIR) / (Red + NIR) \quad \text{(e.q 1)}$$

em que: NDVI - índice de vegetação por diferença normalizada; Red - valor de reflectância da banda do vermelho (780-860nm); e NIR - valor de reflectância da banda do infravermelho próximo (780-860nm)

O processamento estatístico foi realizado por meio do software R 4.2.2. A análise da variância (ANOVA) foi composta de taxa de semeadura como fator fixo e zona de manejo, bloco e interação entre zona de manejo e taxa de semeadura como fator aleatório, além disso o bloco foi hierárquico em relação a zona de manejo. A ANOVA foi conduzida utilizando o pacote "lmerTest". Em caso de diferença significativa entre os tratamentos, testes post-hoc foram conduzidos utilizando Tukey's HSD (Teste de Tukey da Diferença Honestamente Significativa). O pacote "lsmeans" foi utilizado para calcular a HSD e "multcomp" para realizar as comparações de médias. Os gráficos foram gerados utilizando o pacote "ggplot2".

RESULTADOS E DISCUSSÃO

O valor de NDVI em V5 foi significativamente afetado pela zona de manejo e pelo tratamento de taxa de semeadura (FIGURA 2A, B e TABELA 1), no qual a zona de manejo com baixo potencial produtivo resultou em um baixo valor de NDVI, enquanto a zona de manejo com alto potencial produtivo resultou em um alto valor de NDVI. Este resultado pode ser atribuído pela sensibilidade do NDVI às mudanças de biomassa. As zonas de manejo parecem ter influenciado a quantidade de biomassa produzida pela soja nesses estádios iniciais (FARIAS et al., 2023) Além disso, também foi observado que populações maiores resultaram em um aumento de NDVI. Este resultado pode ser sustentado por diversos trabalhos que indicam um aumento de biomassa na soja causado pelo aumento da população em estádios mais novos (SILVA, A., et al., 2021; WERNER, et al., 2016). Pode-se atribuir esse aumento de biomassa no período vegetativo ao fato de ainda não ter ocorrido fechamento de dossel e assim a planta ainda não teve tempo suficiente para expressar a plasticidade de produção de ramos e hastes, visto que posteriormente não ocorreu diferenças em biomassa entre populações, conforme relatado na literatura (COX, et al., 2010; WERNER, et al., 2016).

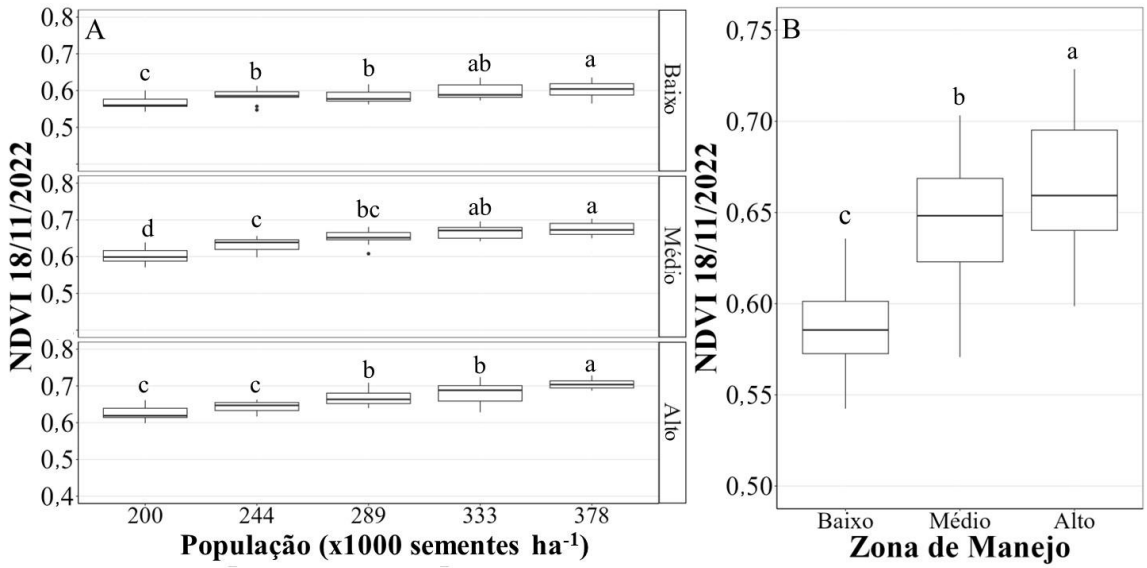


FIGURA 2. NDVI para cada população dentro de cada zona de manejo (A). NDVI para cada zona de manejo (B). Médias seguidas pela mesma letra indicam que não são estatisticamente diferentes de acordo com o teste de Tukey's $HSD_{0,05}$.

Por outro lado, a produtividade média da soja foi de 3,8 Mg ha^{-1}, considerada estatisticamente igual tanto para os ambientes como para a população, não havendo interação significativa entre estes dois fatores (TABELA 1). A ausência de diferença entre as áreas com potenciais produtivos distintos pode ser explicada pelo clima favorável na safra 2022-2023, tendo ocorrido uma safra recorde da região (CONAB, 2023a). A principal diferença entre as zonas de manejo foi a textura, em que a área de baixo potencial produtivo apresentou textura arenosa, enquanto a de alto potencial produtivo possuía mais argilosa. Considerando que a safra foi considerada úmida, a diferença em textura possivelmente não condicionou diferença de produtividade entre as regiões (MOORE; LAWRENCE, 2013; BOCUTI, et al., 2021).

Na literatura não há um consenso em relação a produtividade de soja em resposta da variação de população de plantas, alguns trabalhos reportam que a população tem um efeito positivo sobre a produtividade mesmo em altas taxas de semeadura (SCHUTTE; NLEYA, 2018; CHEN; WIATRAK, 2011; PURUCKER; STEINKE, 2020), mas há outros que reportam não haver efeito da redução da população na produtividade de grãos (COX; CHERNEY, 2011; RIGSBY; BOARD, 2003; VITANTONIO-MAZZINI et al., 2020; SILVA, E., et al., 2021). No presente trabalho foi constatado que não houve diferença significativa entre as populações testadas. Portanto, é possível observar que para as condições deste experimento seria possível reduzir a população de plantas e assim reduzir os custos de produção com manutenção da produtividade. Contudo, Cox e Cherney (2010) observaram que apesar da produtividade não ser afetada na redução de taxas de semeadura, o desbaste de plantas já emergidas causa um efeito de redução de produtividade maior em populações menores. Portanto, em caso de ataques de pragas ou demais fatores que possam reduzir a população final de plantas (e.g., granizo, erosão), a redução de produtividade pode ser maior em populações menores, aumentando o risco do produtor.

Considerando o custo médio de sementes sendo R$ 789 ha^{-1} (CONAB, 2023b) com a população padrão da gleba de 289 mil sementes ha^{-1}, a alteração da população de plantas para a menor taxa utilizada no trabalho permitiria a redução de R$ 243 ha^{-1} no custo de produção.

Por fim, foi observado que a metodologia de experimentação on-farm foi bem-sucedida em sua proposta de realizar um experimento de populações distintas em uma área comercial de soja. E que a metodologia pode ser adotada para trabalhos contínuos visando caracterizar respostas em anos com

condições climáticas distintas a fim de identificar quais glebas e regiões podem ser manejadas de modo mais rentável com populações de plantas variadas.

TABELA 1. Resultado das análises de variância para efeitos do ambiente, bloco, população e da interação entre população e ambiente sobre a produtividade e NDVI

C.V.	G.L.		S.Q.	Q.M.	F	P		S.Q.	Q.M.	F	P
			NDVI					Produtividade (Mg ha^{-1})			
Ambiente	2		0,16	0,08	68,23	0,00		0,17	0,08	0,30	0,74
Bloco (Ambiente)	27		0,03	0,00	4,97	0,00		7,61	0,28	3,35	0,00
População	4		0,07	0,02	77,50	0,00		0,07	0,02	0,21	0,93
População x Ambiente	8		0,01	0,00	4,71	0,00		0,14	0,02	0,20	0,99

onde: C.V., causas de variação; G.L., graus de liberdade; S.Q., soma de quadrados; Q.M., quadrado médio; F, valor F; P, valor P

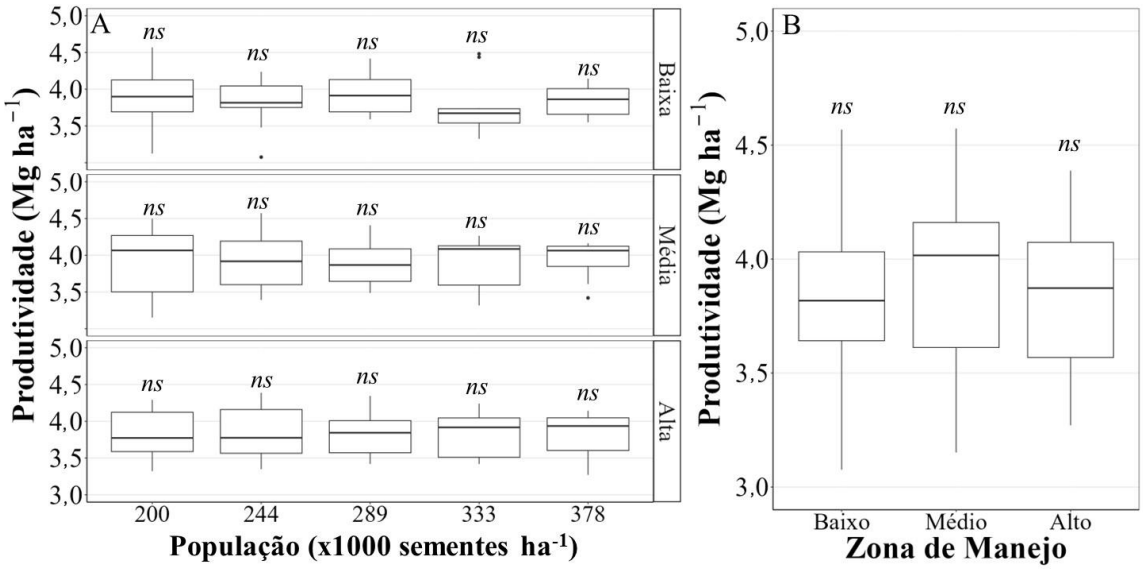


FIGURA 3. Produtividade de grãos para cada população dentro de cada zona de manejo (A). Produtividade de grão para cada zona de manejo (B). *ns*. sem diferença significativa estatisticamente entre os tratamentos com o teste de Tukey's $HSD_{0,05}$.

CONCLUSÃO

A produtividade não foi afetada pela alteração da população de plantas em um amplo intervalo. Para estádios iniciais da soja, o NDVI foi uma ferramenta útil para identificar parcelas com populações distintas. A experimentação on-farm com ferramentas de agricultura de precisão se mostrou viável para condução de experimentos com as máquinas do agricultor e em condições de campos comerciais de produção. Para as condições avaliadas seria possível reduzir a taxa de semeadura sem perdas em produtividade. Os resultados obtidos são restritos às condições climáticas e sua repetição é necessária para compreender os efeitos com cenários climáticos distintos.

AGRADECIMENTOS

Agradecemos ao Grupo Carlos Alberto Polato (GCAP) por apoiar a realização da pesquisa em uma gleba comercial e também aos sócios e proprietários da GeoMec, Leandro Zancanaro e David Valendorff, por incentivar os colaboradores da empresa a realizarem pesquisas aplicada aos problemas do campo.

REFERÊNCIAS

BALBINOT JUNIOR, A. A.; OLIVEIRA, M. C. N.; FRANCHINI, J. C. ; DEBIASI, H.; ZUCARELI, C.; FERREIRA, A. S.; WERNER, F.. Phenotypic plasticity in a soybean cultivar with indeterminate growth type. **Pesquisa Agropecuária Brasileira**, [S.L.], v. 53, n. 9, p. 1038-1044, set. 2018. FapUNIFESP (SciELO). http://dx.doi.org/10.1590/s0100-204x2018000900007.

BOCUTI, Edwaldo D.; AMORIM, Ricardo S. S.; KAVASAKI, Kaynara F. L.; PRADO, Marcelo R. V.; SANTOS, Carlos L. R.; RAIMO, Luis A. di L. di. Soil structure and its relationship with soybean yield. **Revista Brasileira de Engenharia Agrícola e Ambiental**, [S.L.], v. 25, n. 3, p. 168-173, mar. 2021. FapUNIFESP (SciELO). http://dx.doi.org/10.1590/1807-1929/agriambi.v25n3p168-173.

BULLOCK, D. S.; BOERNGEN, M. ; TAO, H. ; MAXWELL, B. ; LUCK, J. D.; SHIRATSUCHI, L. ; PUNTEL, L. ; MARTIN, N. F.. The Data-Intensive Farm Management Project: changing agronomic research through on-farm precision experimentation. **Agronomy Journal**, [S.L.], v. 111, n. 6, p. 2736-2746, nov. 2019. Wiley. http://dx.doi.org/10.2134/agronj2019.03.0165.

CEPEA. **DADOS - CADEIA DA SOJA E DO BIODIESEL**. 2023. Disponível em: https://www.cepea.esalq.usp.br/br/pib-da-cadeia-de-soja-e-biodiesel-1.aspx. Acesso em: 22 mar. 2024.

CHEN, Guihua; WIATRAK, Pawel. Seeding Rate Effects on Soybean Height, Yield, and Economic Return. **Agronomy Journal**, [S.L.], v. 103, n. 5, p. 1301-1307, set. 2011. Wiley. http://dx.doi.org/10.2134/agronj2010.0427.

CONAB. **Acompanhamento da safra brasileira de grãos**. 2023a. Disponível em: https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos/item/download/49098_b2d232d2b5fbe4da1a15d9e457cde081. Acesso em: 22 mar. 2024.

CONAB. **Série Histórica - Custos - Soja - 1997 a 2023**. 2023b. Disponível em: https://www.conab.gov.br/info-agro/custos-de-producao/planilhas-de-custo-de-producao/itemlist/category/824-soja. Acesso em: 22 mar. 2024.

COX, W. J.; CHERNEY, J. H.; SHIELDS, E.. Soybeans Compensate at Low Seeding Rates but not at High Thinning Rates. **Agronomy Journal**, [S.L.], v. 102, n. 4, p. 1238-1243, jul. 2010. Wiley. http://dx.doi.org/10.2134/agronj2010.0047.

EMBRAPA. **Soja em números (safra 2022/23)**. 2023. Disponível em: https://www.embrapa.br/soja/cultivos/soja1/dados-economicos. Acesso em: 22 mar. 2024.

FARIAS, Gustavo Duarte; BREMM, Carolina; BREDEMEIER, Christian; MENEZES, Jeferson de Lima; ALVES, Lucas Aquino; TIECHER, Tales; MARTINS, Amanda Posselt; FIORAVANÇO, Gabriela Paiva; SILVA, Gabriela Petry da; CARVALHO, Paulo César de Faccio. Normalized Difference Vegetation Index (NDVI) for soybean biomass and nutrient uptake estimation in response to production systems and fertilization strategies. Frontiers In **Sustainable Food Systems**, [S.L.], v. 6, n. 1, p. 1-12, 9 jan. 2023. Frontiers Media SA. http://dx.doi.org/10.3389/fsufs.2022.959681.

GREGO, C. R. et al. EXPERIMENTAÇÃO ON-FARM NO SISTEMA DE AGRICULTURA DE PRECISÃO EM CANA-DE-AÇÚCAR. In: CONGRESSO BRASILEIRO DE AGRICULTURA DE PRECISÃO- CONBAP, 2022, Campinas. **Anais [...]** . Campinas: Asbraap, 2022. p. 422-426.

MOORE, S. R., & LAWRENCE, K. S.. The Effect of Soil Texture and Irrigation on Rotylenchulus reniformis and Cotton. **Journal of nematology**,[S.L.] v. 45, n. 2, p. 99-105, jun. 2013. PubMed Central.

PURUCKER, T.; STEINKE, K.. Soybean seeding rate and fertilizer effects on growth, partitioning, and yield. **Agronomy Journal**, [S.L.], v. 112, n. 3, p. 2288-2301, 17 abr. 2020. Wiley. http://dx.doi.org/10.1002/agj2.20208.

RIGSBY, B.; BOARD, J. E.. Identification of Soybean Cultivars That Yield Well at Low Plant Populations. **Crop Science**, [S.L.], v. 43, n. 1, p. 234-239, jan. 2003. Wiley. http://dx.doi.org/10.2135/cropsci2003.2340.

ROBERT, Pierre. Characterization of soil conditions at the field level for soil specific management. **Geoderma**, [S.L.], v. 60, n. 1-4, p. 57-72, dez. 1993. Elsevier BV. http://dx.doi.org/10.1016/0016-7061(93)90018-g.

SCHUTTE, Matthew; NLEYA, Thandiwe. Row Spacing and Seeding Rate Effects on Soybean Seed Yield. **Soybean - Biomass, Yield And Productivity**, [S.L.], p. 226-234, 20 fev. 2019. IntechOpen. http://dx.doi.org/10.5772/intechopen.80748.

SILVA, Alessandro Guerra da; MARTINS, Paula Daiane de Sena; CARMO, Eduardo Lima do; PROCÓPIO, Sérgio de Oliveira; ANDRADE, Christiano Lima Lobo de; CALDAS, Joao Victor Santos; FERREIRA JÚNIOR, José Carlos. INFLUÊNCIA DO ESPAÇAMENTO ENTRELINHAS E DA POPULAÇÃO DE PLANTAS A UMA CULTIVAR DE SOJA DE HÁBITO DE CRESCIMENTO INDETERMINADO. **Nucleus**, [S.L.], v. 18, n. 1, p. 43-61, 30 abr. 2021. Fundacao Educational de Ituverava. http://dx.doi.org/10.3738/1982.2278.3857.

SILVA, E. E.; BAIO, F. H. R.; TEODORO, L. P. R.; CAMPOS, C. N. S.; PLASTER, O. B.; TEODORO, Paulo Eduardo. Variable-rate seeding in soybean according to soil attributes related to grain yield. **Precision Agriculture**, [S.L.], v. 23, n. 1, p. 35-51, 16 jun. 2021. Springer Science and Business Media LLC. http://dx.doi.org/10.1007/s11119-021-09826-7.

SPERANZA, E. A. et al. DELINEAMENTO DE ZONAS DE MANEJO PARA O PLANEJAMENTO DE EXPERIMENTAÇÃO ON-FARM NA CULTURA DO ALGODÃO. In: CONGRESSO BRASILEIRO DE AGRICULTURA DE PRECISÃO- CONBAP 2022, Campinas. **Anais [...]** . Campinas: Asbraap, 2022. p. 386-395.

VITANTONIO-MAZZINI, L. N.; GÓMEZ, D. ; GAMBIN, B. L.; MAURO, G. ; IGLESIAS, R. ; COSTANZI, J. ; JOBBÁGY, E. G.; BORRÁS, L. . Sowing date, genotype choice, and water environment control soybean yields in central Argentina. **Crop Science**, [S.L.], v. 61, n. 1, p. 715-728, 8 nov. 2020. Wiley. http://dx.doi.org/10.1002/csc2.20315.

WERNER, Flávia; BALBINOT JUNIOR, Alvadi A.; FERREIRA, André S.; SILVA, Marcelo A. de A. e; DEBIASI, Henrique; FRANCHINI, Julio C.. Soybean growth affected by seeding rate and mineral nitrogen. **Revista Brasileira de Engenharia Agrícola e Ambiental**, [S.L.], v. 20, n. 8, p. 734-738, ago. 2016. FapUNIFESP (SciELO). http://dx.doi.org/10.1590/1807-1929/agriambi.v20n8p734-738.

ANÁLISE ESPACIAL DA PRODUTIVIDADE DE CENOURA IRRIGADA CORRELACIONADA COM ATRIBUTOS QUÍMICOS DO SOLO

Gloria Milena Rojas Plazas [1]; Erli Pinto dos Santos [1]; Job Teixeira de Oliveira [2]; Rubens Alves de Oliveira [3]

[1]Bolsista. Av. P H Rolfs, s/n - Campus Universitário, Viçosa - MG, 36570-900. Universidade Federal de Viçosa ; [2]Docente. Rod MS 306, Km 105, CXP 112 , Chapadão do Sul - MS, 79560-000. Universidade Federal de Mato Grosso do Sul; [3]Docente. Av. P H Rolfs, s/n - Campus Universitário, Viçosa - MG, 36570-900. Universidade Federal de Viçosa

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A caracterização da variabilidade e dependência espacial dos atributos químicos do solo e produtividade da cultura de cenoura é essencial para avaliar a resposta da cultura a práticas de manejo a sítio específico. Objetivou-se nesta pesquisa determinar como a produtividade da cultura de cenoura irrigada é afetada pela variabilidade espacial dos atributos químicos do solo. O estudo foi desenvolvido na safra 2021 em Campos Altos, MG, Brasil, numa cultura de cenoura irrigada. Na área foram estabelecidos 100 pontos amostrais distribuídos em uma área quadrada de 40.000 m^2. Em cada ponto, foi avaliada a produtividade da cenoura e os atributos químicos do solo. Realizou-se análise geoestatística para analisar a variabilidade e dependência espacial dos atributos químicos do solo e produtividade da cultura. Foi possível constatar média variabilidade na produtividade. Por outro lado, evidenciou-se que os atributos químicos do solo que apresentaram um coeficiente de variação maior do que 20%, indicando alta heterogeneidade, foram o fósforo disponível e o potássio disponível. Dentre as variáveis que apresentaram dependência espacial, o menor alcance correspondeu a 42 m para o cálcio trocável. A variável que melhor estimou a variabilidade espacial da produtividade da cenoura foi a capacidade de troca catiônica potencial, mostrando correlação espacial positiva.

PALAVRAS-CHAVE: *Daucus carota* L.; dependência espacial; geoestatística

ABSTRACT

The characterization of the variability and spatial dependence of soil chemical attributes and carrot crop productivity is essential for assessing the crop's response to site-specific management practices. The objective of this research was to determine how the productivity of irrigated carrot crops is affected by the spatial variability of soil chemical attributes. The study was conducted during the 2021 growing season in Campos Altos, MG, Brazil, in an irrigated carrot crop. One hundred sampling points were established in the area, distributed in a square area of 40,000 m2. At each point, carrot productivity and soil chemical attributes were evaluated. Geostatistical analysis was performed to analyze the variability and spatial dependence of soil chemical attributes and crop productivity. It was found that there was average variability in productivity. On the other hand, it was evident that soil chemical attributes with a coefficient of variation greater than 20%, indicating high heterogeneity, were available phosphorus and available potassium. Among the variables showing spatial dependence, the smallest range corresponded to 42 m for exchangeable calcium. The variable that best estimated the spatial variability of carrot productivity was potential cation exchange capacity, showing positive spatial correlation.

KEYWORDS: *Daucus carota* L.; geostatistics; spatial dependence

INTRODUÇÃO

A cenoura (*Daucus carota* L.) é uma olerícola pertencente à família Apiaceae. É uma raiz nutritiva amplamente cultivada em nível mundial (QUE et al., 2019). No contexto da agricultura brasileira, a cenoura é uma das hortaliças mais consumidas, sendo cultivada em todo o país. Minas Gerais é o estado com maior destaque na produção de cenoura, devido especialmente ao alto nível tecnológico adotado na região de São Gotardo (CARVALHO et al., 2021).

O desenvolvimento, produtividade e qualidade das lavouras de cenoura estão influenciadas por fatores pedoclimáticos, variedade e práticas agronômicas e de manejo (GUIMARÃES et al., 2018). Numerosos estudos exploraram as respostas da cenoura a diferentes práticas de manejo (MONTAZAR; GEISSELER; CAHN, 2021; SILVA et al., 2021; SZELAG-SIKORA et al., 2019). Estas descobertas destacam a importância de estudar e caracterizar a variabilidade espacial dos atributos químicos do solo para avaliar o seu impacto nas respostas das culturas às práticas de manejo a sítio específico. Dada a importância econômica das culturas de cenoura, é essencial otimizar a gestão através de técnicas de agricultura de precisão (WEI et al., 2020).

Essa otimização pode levar ao aumento do rendimento, mantendo ou melhorando a qualidade do solo. A aplicação da geoestatística permite caracterizar a estrutura e magnitude da dependência espacial dos atributos químicos do solo e a produtividade da cultura de cenoura. Isso possibilita a definição de regras de manejo que promovam um melhor gerenciamento dos insumos consumidos para o ótimo desenvolvimento da cultura sem afetar a produtividade e qualidade do produto.

OBJETIVOS

Objetivou-se na presente pesquisa avaliar a variabilidade e dependência espacial dos atributos químicos do solo em uma cultura de cenoura cultivada sob irrigação.

MATERIAL E MÉTODOS

A pesquisa foi realizada na safra do ano 2021, numa área de produção da fazenda Iamaguti, localizada em Campos Altos (19°25'16.8" S e 46°09'23.2" W, altitude média de 1200 m), Minas Gerais, Brasil. A irrigação da cultura é realizada por pivô central. Segundo BECK et al. (2018), o clima da região é corresponde ao tipo Cwa, segundo a classificação de classificação de Köppen & Geiger (1928). Os solos predominantes da região são classificados como Latossolos de textura consideravelmente argilosa (SANTOS et al., 2018).

O preparo do solo e o manejo da cultura seguiram o sistema de plantio convencional. A cenoura foi plantada mecanicamente, em canteiros de 2 m de largura, contendo 5 fileiras de plantas em cada canteiro. Foi usada a cultivar Natuna, com uma densidade de semeadura de 681.818 sementes ha^{-1}.

A amostragem de solo foi realizada por meio de locação de pontos amostrais na malha de 20 x 20 m, totalizando 100 pontos amostrais na área estudada. Em cada ponto de amostragem foi coletada uma amostra de solo deformada na camada de 0 a 0,30 m de profundidade. Na sequência, foram determinados os teores de K e P disponível, em mg dm^{-3}; Ca^{2+} trocável, em cmolc dm^{-3}; N total, em dag kg^{-1}, capacidade de troca catiônica efetiva (t), capacidade de troca catiônica potencial (T) e acidez potencial (H+Al), em cmolc dm^{-3} e o P-Rem (mg L^{-1}).

Amostragem de planta: 167 dias após a semeadura da cenoura, foram realizadas amostragens de cinco plantas de cenoura em cada ponto amostral. A produtividade da cenoura (PRO), em t ha^{-1}, foi obtida por meio da massa fresca total das raízes coletadas.

O estudo da variabilidade e dependência espacial foi realizado mediante o software GS^{+}. Assim, foram realizados os ajustes dos semivariogramas simples e cruzados. O grau de dependência espacial (GD) foi avaliado mediante o avaliador de dependência espacial, em que GD ≤ 25% representam uma

dependência espacial fraca, de 25 - 75% dependência espacial moderada e ≥ 75% dependência espacial forte (FILHO et al., 2011).

RESULTADOS E DISCUSSÃO

Os parâmetros dos semivariogramas simples para a produtividade da cenoura e os atributos químicos do solo estão apresentados na Tabela 1 e Figura 1. Os atributos químicos do solo N, H+Al, e t não indicaram dependência espacial (resultados não apresentados na tabela).

Tabela 1. Parâmetros dos semivariogramas simples ajustados para a produtividade da cenoura, e atributos químicos do solo

Atributo[(1)]	**Modelo**[(2)]	**Efeito pepita (C_0)**	**Patamar (C_1)**	**Alcance (m)**	**R^2**	**SQR**[(3)]	**ADE**[(4)]		**Validação Cruzada**[(5)]		
							(%)	**Classe**	**a**	**b**	**r**
PR	EXP	18,60	140,0	47	0,63	541,00	86,70	Forte	23,58	0,76	0,33
P	EXP	33,700	211,400	59	0,40	5589,00	84,10	Forte	-1,32	1,03	0,43
K	ESF	69,900	144,300	134	0,92	363,00	51,80	Moderada	-1,70	1,03	0,50
Ca	EXP	0,021	0,135	42	0,42	1,06E-03	84,40	Forte	-1,20	1,31	0,41
T	EXP	0,017	0,182	92	0,86	1,32E-03	90,60	Forte	-0,32	1,03	0,64
P_Rem	EXP	0,060	0,455	70	0,71	0,01	86,80	Forte	1,86	0,84	0,404

(1) PR: Produtividade da cenoura (t ha^{-1}); **Atributos químicos do solo:** P: fósforo disponível, K: potássio disponível, Ca: cálcio trocável, T: CTC potencial, em $cmol_C$ dm^{-3}, P_Rem: fósforo remanescente, em mg L^{-1}, (2) EXP: exponencial; ESF: esférico; (3) soma de quadrado de resíduos; (4) avaliador da dependência espacial; (5) a: coeficiente linear, b: coeficiente angular.

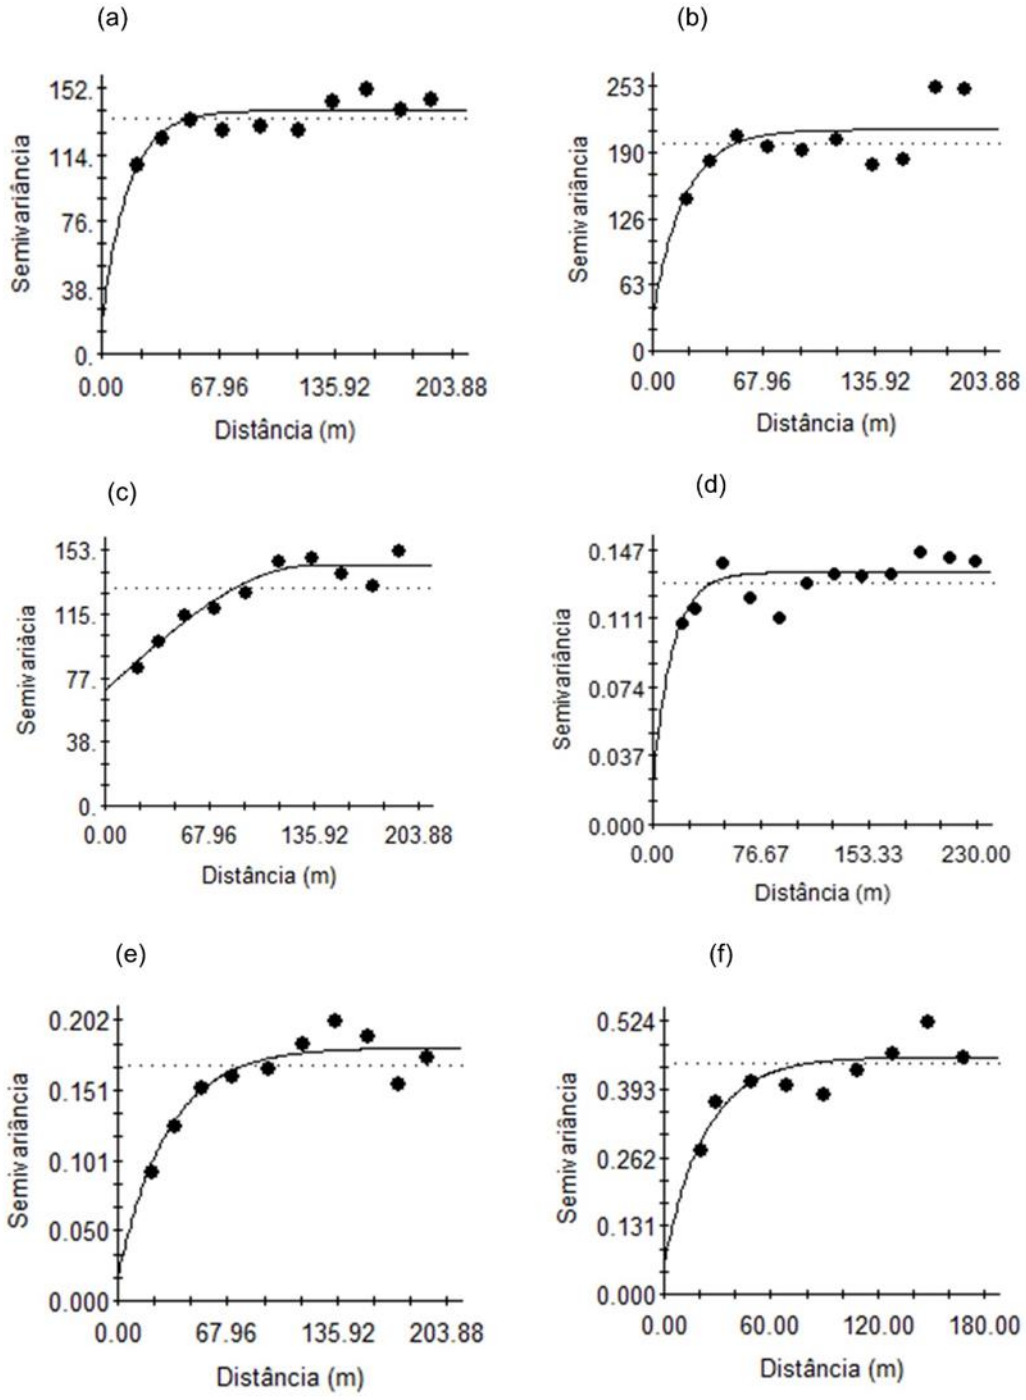


Figura 1. Semivariogramas simples ajustados para os atributos físico-químicos do solo, em que: (a) Produtividade da cenoura, (b) fósforo disponível, (c) potássio disponível, (d) cálcio trocável, (e) CTC potencial, em $cmol_c\ dm^{-3}$, (f) fósforo remanescente, em mg L^{-1}.

O alcance do semivariograma corresponde à distância máxima dentro da qual existe correlação ou dependência espacial, sendo o principal parâmetro fornecido pela geoestatística (BEHERA et al., 2018). Em relação aos atributos químicos do solo, o alcance variou de 42,0 m para o cálcio até 134,0 m para o K. Sugere-se que, no geral, em estudos relativos aos atributos químicos do solo em cultura de cenoura irrigada na região de Campos Altos, as amostragens não sejam maiores que os valores de intervalos apresentados aqui (máximo 42 m).

As figuras 2a a 2f apresentam os mapas de distribuição gerados por meio da krigagem ordinária após o ajuste dos semivariogramas, mediante os quais foi possível visualizar a variabilidade espacial dos

diferentes atributos na área.Quando se analisa o mapa de produtividade obtido (Figura 2a), percebe-se que a região norte da lavoura exibiu as maiores produtividades. Pode-se observar adicionalmente que boa parte da área está classificada como de produtividade média, encontrando-se ainda acima da média indicada por CARVALHO et al. (2021), para a região de estudo (70 toneladas ha-1).

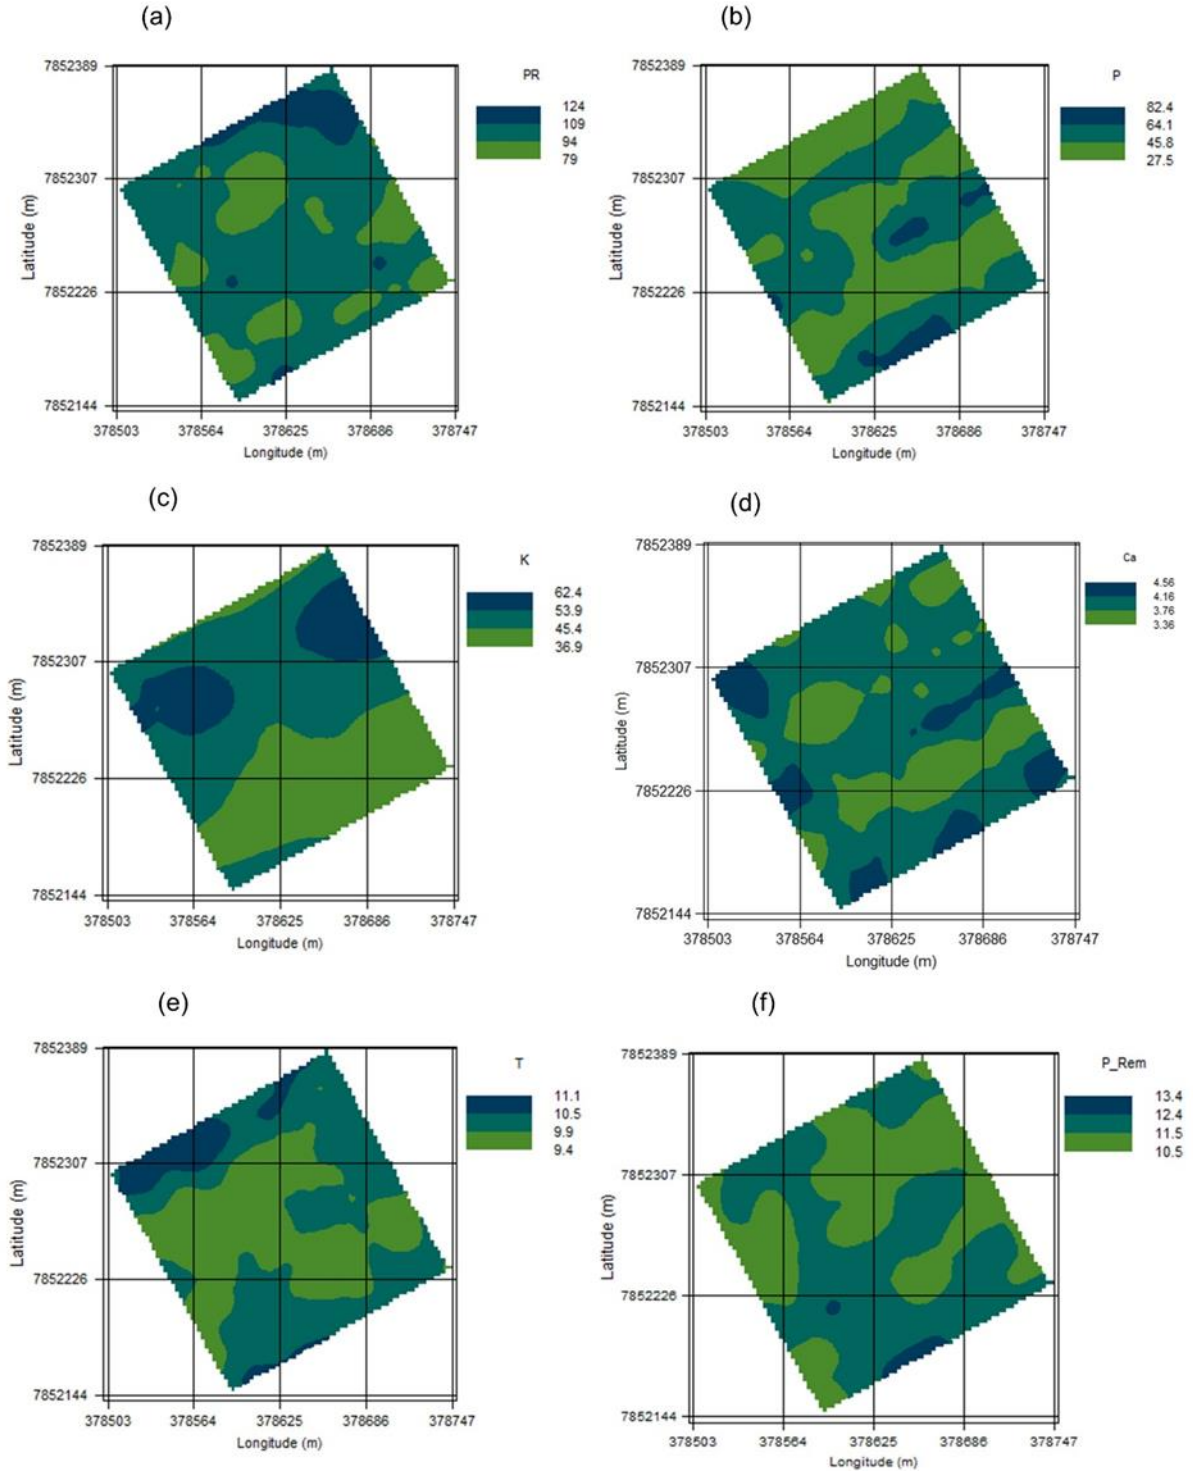


Figura 2. Mapas de krigagem simples químicos do solo, em que: (a) produtividade da cenoura (t ha^{-1}); (b) fósforo disponível, (c) potássio disponível, (d) cálcio trocável, (e) CTC potencial, em cmolC dm^{-3}, (f) fósforo remanescente, em mg L^{-1}.

Quando se analisa o mapa de produtividade obtido (Figura 2a), percebe-se que a região norte da lavoura exibiu as maiores produtividades. Pode-se observar adicionalmente que boa parte da área está

classificada como de produtividade média, encontrando-se ainda acima da média indicada por CARVALHO et al. (2021), para a região de estudo (70 toneladas ha-1).

O fósforo exibiu padrão de distribuição variado na área de estudo (Figura 2b). Evidencia-se que as regiões com menores valores de P disponível estão seguindo a direção dos canteiros, principalmente na região centro e norte da área. Sendo o P um elemento de baixa mobilidade, infere-se que o padrão de variabilidade encontrado seja produto das práticas de adubação realizadas. Os valores de P variaram de 27,5 a 82,4 mg dm^{-3}, apresentando 100% das amostras uma disponibilidade classificada como muito boa, de acordo com a classificação proposta por RIBEIRO; GUIMARÃES; ALVAREZ (1999). O baixo valor do P-rem (11,55 mg L-1) está em conformidade com DEZORDI et al. (2016), que indicaram que os solos da região possuem uma alta capacidade tampão para este nutriente, requerendo assim a adição de grandes quantidades de fertilizante ao solo para aumentar a fração de P disponível para a cultura.

A distribuição espacial do K foi mostrada na Figura 2c. Os valores de K do solo de toda a área variaram de 36,9 a 62,4 cmolc dm-3, apresentando os menores valores na região sul da lavoura. Da mesma forma que para o P, é possível avaliar uma possível economia no uso deste fertilizante nas regiões com os maiores teores amostrados.

A deterioração da qualidade da água é um dos maiores problemas ambientais globais. A agricultura é considerada a maior fonte difusa de poluição de água, devido especialmente ao uso indiscriminado de fertilizantes. Aplicações repetidas e prolongadas de fertilizantes causam um acúmulo de nutrientes no solo que, por lixiviação e escoamento superficial, penetram nos lençóis freáticos e nos recursos hídricos superficiais (ABD-ELATY et al., 2020). Diante disso, uma diminuição nos excedentes de fertilizantes não só representará uma economia para o produtor, mas contribuirá também na diminuição da lixiviação, evitando contaminação de águas subterrâneas e superficiais.

Em relação à cokrigagem (Figura 3), verificou-se uma correlação espacial significativa e positiva para a produtividade da cenoura em razão do atributo químico CTC potencial a pH 7 (PR=f(T)).

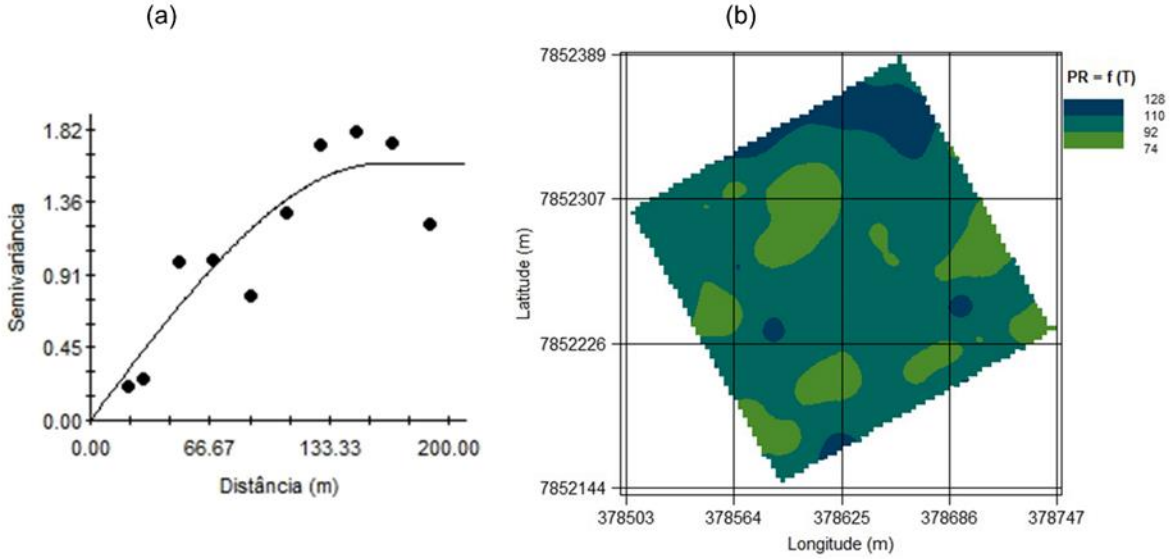


Figura 3. (a) Semivariograma cruzado e (b) mapa de cokrigagem da produtividade da cenoura em função da CTC potencial.

O coeficiente de determinação espacial R^2 para PR=f(T) foi de 0,82. Assim, pode se evidenciar que, espacialmente, a CTC potencial do solo contribue na produção de cenoura acima de 80%.

CONCLUSÃO

A cenoura apresentou alta produtividade (99,74 t ha^{-1}), sendo superior à média reportada para a região de estudo. A variável dependente que apresentou o menor alcance foi o Ca (42,0 m) entre os atributos químicos do solo. Entre os atributos avaliados, a CTC potencial a pH 7 foi o melhor indicador para estimar a variabilidade espacial da produtividade de cenoura irrigada por pivô central no município de Campos Altos.

REFERÊNCIAS

ABD-ELATY, I. et al. Simulation-based solutions reducing soil and groundwater contamination from fertilizers in arid and semi-arid regions: Case study the eastern nile delta, egypt. International Journal of Environmental Research and Public Health, v. 17, n. 24, p. 1-18, 2020.

BECK, H. E. et al. Present and future Köppen-Geiger climate classification maps at 1-km resolution. Scientific Data 2018 5:1, v. 5, n. 1, p. 1-12, 30 out. 2018.

BEHERA, S. K. et al. Spatial variability of soil properties and delineation of soil management zones of oil palm plantations grown in a hot and humid tropical region of southern India. Catena, v. 165, n. June 2017, p. 251-259, 2018.

CARVALHO, A. D. F. et al. Sistemas de Produção - Cenoura. Embrapa Hortaliças, p. 74, 2021.

DEZORDI, L. R. et al. Diagnostic Methods to Assess the Nutritional Status of the Carrot Crop. Revista Brasileira de Ciência do Solo, v. 40, 2016.

FILHO, G. R. et al. Variabilidade espacial de propriedades dendrométricas do eucalipto e de atributos físicos de um Latossolo Vermelho Spatial variability of dendrometric properties of eucalyptus and physical attributes of a Rhodic Eutrudox. Bragantia, v. 70, n. 2, p. 439-446, 2011.

GUIMARÃES, C. et al. Moisture Behavior to the Spatial Variability of Physical Attributes in Different Soil Management. Journal of Experimental Agriculture International, v. 25, n. 1, p. 1-8, 2018.

KÖPPEN W.; GEIGER R. Klimate der Erde. Justus Perthes, Gotha, 1928.

MONTAZAR, A.; GEISSELER, D.; CAHN, M. Spatial variability of nitrogen uptake and net removal and actual evapotranspiration in the California desert carrot production system. Agriculture (Switzerland), v. 11, n. 8, 2021.

QUE, F. et al. Advances in research on the carrot, an important root vegetable in the Apiaceae family. Horticulture Research, 2019.

RIBEIRO, A. C.; GUIMARÃES, P. T. G.; ALVAREZ, V. H. Recomendações para o uso de corretivo e fertilizantes em Minas Gerais - 5a aproximação. Viçosa, Minas Gerais: UFV, 1999.

SANTOS, H. G. DOS et al. Sistema brasileiro de classificação de solos. 3. ed. Brasília: 2018.

SILVA, J. C. et al. Combination of irrigation and fertilizer increases yield and economic profit in carrot production. Brazilian Journal of Agricultural and Environmental Engineering, v. 25, p. 807-812, 2021.

SZELAG-SIKORA, A. et al. Impact of integrated and conventional plant production on selected soil parameters in carrot production. Sustainability (Switzerland), v. 11, n. 20, 2019.

WEI, M. C. F. et al. Carrot Yield Mapping: A Precision Agriculture Approach Based on Machine Learning. Ai, v. 1, n. 2, p. 229-241, 2020.

CORRELAÇÃO ENTRE ÍNDICES ESPECTRAIS RGB E A PRODUTIVIDADE DE GRÃOS DE MILHO

GABRIEL FERREIRA DE OLIVEIRA [1]; ANA BEATRIZ DANTAS LOPES [2]; MARCELO COELHO FURTADO [3]; ANAIDE CAROLANE DA SILVA SANTOS [4]; MIGUEL JULIO MACHADO GUIMARÃES [5]

[1]Graduando em Agronomia . BR-230, São Raimundo das Mangabeiras - MA, 65840-000. Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, São Raimundo das Mangabeiras; [2]Engº Agrônoma. BR-230, São Raimundo das Mangabeiras - MA, 65840-000. Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, São Raimundo das Mangabeiras; [3]Engº Agrônomo. BR-230, São Raimundo das Mangabeiras - MA, 65840-000. Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, São Raimundo das Mangabeiras; [4]Graduanda em Agronomia . BR-230, São Raimundo das Mangabeiras - MA, 65840-000. Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, São Raimundo das Mangabeiras; [5]Engº Agrônomo, Doutor em Engenharia Agrícola, Professor. BR-230, São Raimundo das Mangabeiras - MA, 65840-000. Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, São Raimundo das Mangabeiras

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

O objetivo deste estudo foi verificar a correlação entre índices de vegetação do espectro RGB com a produtividade de grãos de milho em duas safras de cultivo. Os experimentos foram realizados no Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, Campus São Raimundo das Mangabeiras, nos anos de 2022 e 2023. A área experimental foi plantada com a variedade de milho BM 3066, e o preparo do solo e o manejo de pragas e doenças foram realizados conforme recomendações comerciais para a cultura do milho. Foram realizadas coletas de imagens aéreas na fase fenológica R4 da cultura. O processamento das imagens foi feito usando a técnica SFM, e o software QGIS utilizado para aplicar os índices de vegetação NGRDI, GLI, VARI e ExG. Para determinar a produtividade de grãos de milho, espigas foram coletadas em pontos georreferenciados. Em posse dos dados de índices de vegetação e produtividade de grãos de milho, foram realizadas análises descritivas e de correlação entre as variáveis. Os resultados obtidos neste estudo evidenciam que os índices de vegetação VARI, GLI, NGDRI e EXG apresentam o mesmo comportamento espectral na avaliação de cultivos de milho. Os índices VARI e NGDRI apresentam correlações positivas e significativas com a produtividade de grãos de milho, podendo ser utilizados em estudos com o objetivo de estimar a produtividade.

PALAVRAS-CHAVE: Geoprocessamento; drone; avaliação de cultivos

ABSTRACT

The aim of this study was to verify the correlation between vegetation indices in the RGB spectrum and corn grain yield in two crop seasons. The experiments were carried out at the Federal Institute of Education, Science and Technology of Maranhão, São Raimundo das Mangabeiras Campus, in the years 2022 and 2023. The experimental area was planted with the BM 3066 corn variety, and soil preparation and pest and disease management were carried out in accordance with commercial recommendations for growing corn. Aerial images were taken during the R4 phenological phase of the crop. The images were processed using the SFM technique and the QGIS software was used to apply the NGRDI, GLI, VARI and ExG vegetation indices. To determine corn grain yield, ears were collected at georeferenced points. With the data on vegetation indices and corn grain yield, descriptive and correlation analyses were carried out between the variables. The results obtained in this study show that the VARI, GLI, NGDRI and EXG vegetation indices have the same spectral behavior when evaluating corn crops. The VARI and NGDRI indices show positive and significant correlations with corn grain yield and can be used in studies to estimate yield.

KEYWORDS: ;

INTRODUÇÃO

A cultura do milho, em função do seu alto potencial de produção, composição química e valor nutricional, constitui um dos mais importantes cereais cultivados e consumidos no mundo (SOARES, 2010). Com produção superior a 105,2 milhões de toneladas, na safra 2020/2021, e produtividade média de 5,19 t ha^{-1}, sendo o Brasil o terceiro produtor mundial, depois dos EUA e China (CONAB, 2023). A produção de milho no Brasil contribui com cerca de 80% da produção de grãos.

A cultura do milho assume importante papel socioeconômico entre as culturas de interesse econômico no Nordeste Brasileiro, em virtude de se constituir em matéria-prima impulsionadora de diversos complexos agroindustriais. Na região sul do Maranhão, o milho exerce papel de destaque na economia dado a sua larga importância na alimentação humana e animal, como por exemplo, a produção de grãos, sendo uma das principais culturas agrícola comerciais.

Sabendo-se dos diversos desafios que a produção agrícola enfrenta, é de extrema relevância entender e agregar conhecimentos nas áreas das geotecnologias para o planejamento e tomada de decisão no que se refere a manutenção e aquisição de áreas para plantio, uso adequado de recursos hídricos, irrigação e acompanhamento de dinâmicas da vegetação, entre outros. A pesquisa e monitoramento da vegetação em ambientes agrícolas e em áreas de conservação ambiental têm se destacado como um dos tópicos mais abordados e debatidos no campo do Sensoriamento Remoto (SR) quando aplicado à temática agrícola.

OBJETIVOS

Com isto, o objetivo deste estudo foi verificar a correlação entre índices de vegetação do espectro RGB com a produtividade de grãos de milho em duas safras de cultivo.

MATERIAL E MÉTODOS

O experimento foi realizado no Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, Campus São Raimundo das Mangabeiras, nos anos de 2022 e 2023. a região apresenta clima do tipo Aw quente com estação seca no inverno e úmida no verão. Apresenta temperaturas médias anuais de 26,4 °C e precipitação média anual de 1157 mm. O solo do local é classificado como Latossolo Amarelo distrófico (SILVA, 2018). A área experimental de 3,0 hectares foi plantada com a variedade de milho BM 3066, com espaçamento de 0,20 m entre plantas e 0,40 m entre linhas. O preparo do solo e o manejo de pragas e doenças foram realizados conforme recomendações comerciais para a cultura do milho.

Foram realizadas coletas de imagens aéreas com uma ARP DJI Mavic Air 2S na fase fenológica R4 da cultura. Os voos foram feitos a 80 m de altura e 6 m/s de velocidade, com sobreposição de 80%. O processamento das imagens foi feito usando a técnica SFM (do inglês - *Structure from motion*) que realiza a reconstrução de estruturas tridimensionais a partir de sequências de imagens bidimensionais coletadas em sensores em movimento, e o software QGIS 3.14 para aplicar os índices de vegetação NGRDI (TUCKER, 1979), GLI (LOUHAICHI et al., 2001), VARI (GITELSON et al., 2002) e ExG (WOEBBECKE et al., 1995).

Para determinar a produtividade do milho, amostras foram coletadas em 40 pontos georreferenciados utilizando o método posicionamento relativo cinemático, com um par de aparelhos GNSS do modelo FOIF A30. A colheita foi realizada quando o milho se encontraca com uma umidade de grãos de 13%. Em cada ponto de coleta colheu-se três plantas, as quais foram colocadas em sacos de papel e pesadas

em balanças analíticas para determinação do peso de biomassa fresca, posteriormente foram secas em estufa de ventilação forçada a 65 °C para determinação do peso seco. Após a pesagem, os valores de produção foram multiplicados pelo estande da área para determinar a produtividade em (t ha^{-1}). Após a aplicação dos índices de vegetação, foram determinados os valores médios em cada ponto de amostragem da produtividade através da função Estatística zonais no software QGIS.

RESULTADOS E DISCUSSÃO

Através dos dados apresentados na Figura 1 pode-se observar que a área avaliada apresentou uma maior variabilidade dos índices de vegetação aplicados na safra de 2022. No entanto, quando avaliados os valores médios, verifica-se que a área de cultivo apresentou comportamento similar nas duas safras avaliadas. Quando avaliada a produtividade de grãos, pode observar que a safra 2023 apresentou uma produtividade média muito superior que a safra 2022. Os resultados corroboram com os estudos desenvolvidos por Vian et al. (2016), os quais concluíram que a produtividade de milho apresenta elevada variabilidade espacial e temporal, e que esta variabilidade está condicionada por aspectos relacionados ao estabelecimento e desenvolvimento da cultura, bem como os fatores climáticos da região de cultivo.

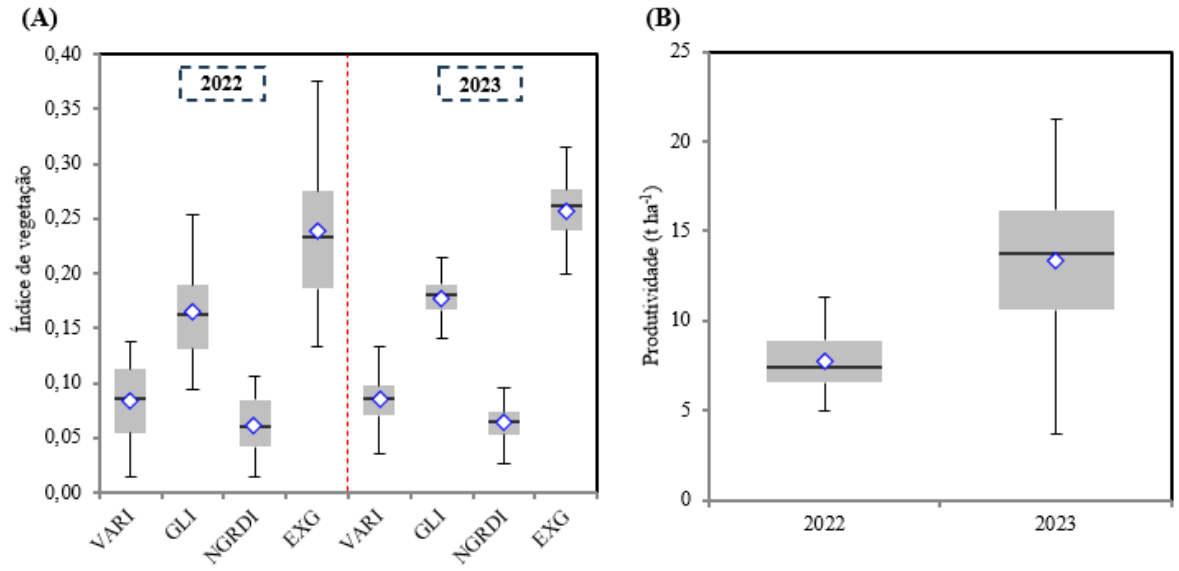


FIGURA 1. *Boxplot* estatístico dos valores de índices espectrais RBG (A) e da produtividade de grãos de milho (B) nas safras 2022 e 2023.

A Tabela 1 apresenta a correlação entre os índices de vegetação e a produtividade de grãos de milho nas safras 2022 e 2023 na região do sul do Maranhão. Pode-se observar correlações positivas significativas entre todos os índices de vegetação avaliados nos dois anos de cultivo. Estes resultados evidenciam que os índices avaliados apresentam o mesmo comportamento espectral na avaliação de cultivos de milho.

TABELA 1. Correlação entre índices de vegetação e a produtividade de grãos de milho em duas safras de cultivo.

			SAFRA 2022		
Variável	VARI	GLI	NGRDI	EXG	Prod.
VARI	1,00				

GLI	0,73***	1,00			
NGRDI	0,96***	0,84***	1,00		
EXG	0,73***	1,00***	0,84***	1,00	
Prod.	**0,48****	0,19	0,33	0,19	1,00
		SAFRA 2023			
Variável	VARI	GLI	NGRDI	EXG	Prod.
VARI	1,00				
GLI	0,90***	1,00			
NGRDI	0,99***	0,92****	1,00		
EXG	0,89***	1,00***	0,93***	1,00	
Prod.	**0,44***	0,36	**0,44***	0,35	1,00

Quando avaliadas as correlações entre os índices espectrais e a produtividade de grãos, foi possível verificar correlações significativas apenas para o índice VARI nas duas safras avaliadas, e NGDRI na safra de 2023. A correlação entre índices espectrais e a produtividade de cultivos agrícolas já foi avaliada por outros autores. Luna Neto et al. (2023) não observou correlação significativa entre índices de vegetação e a produtividade de grãos de milho submetido a aplicação de bioestimulantes. Já García-Martínez et al. (2020) observaram correlações significativas entre índices de vegetação e a produtividade de grãos de milho, e concluíram que índices que apresentam boas correlações com a produtividade podem ser utilizados em modelos de predição da produção.

A Figura 2 apresenta os gráficos de dispersão entre a produtividade de grãos e os índices VARI e NGDRI, os quais apresentaram correlação significativa. Pode-se observar que, apesar de obterem valores de correlação significativa, os mesmo apresentam grande dispersão gráfica e baixos valores de R². Estes resultados estão de acordo com os dados obtidos por García-Martínez et al. (2020) quando avaliaram a correlação entre índices de vegetação e a produtividade de grãos de milho.

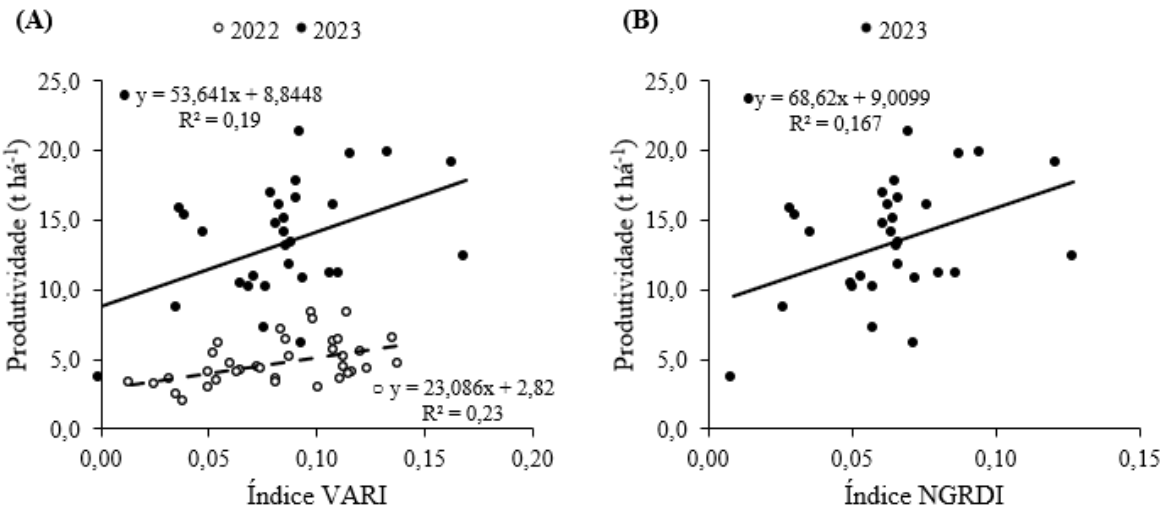


FIGURA 2. Dispersão entre a produtividade de grãos e os índices de vegetação VARI e NGDRI em duas safras de cultivo de milho. (A) - Índice VARI; (B) - Índice NGRDI.

CONCLUSÃO

Os resultados obtidos neste estudo evidenciam que os índices de vegetação VARI, GLI, NGDRI e EXG apresentam o mesmo comportamento espectral na avaliação de cultivos de milho. Os índices VARI e NGDRI apresentam correlações positivas e significativas com a produtividade de grãos de milho, podendo ser utilizados em estudos com o objetivo de estimar a produtividade.

AGRADECIMENTOS

Ao Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, Campus São Raimundo das Mangabeiras, pelo apoio institucional.

REFERÊNCIAS

CONAB (Companhia Nacional de Abastecimento). Acompanhamento de safra brasileira 22/23. Disponível em https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos. Acesso em: 29 mar. 2024.

GARCÍA-MARTÍNEZ, H.; FLORES-MAGDALENO, H.; ASCENCIO-HERNÁNDEZ, R.; KHALIL-GARDEZI, A.; TIJERINA-CHÁVEZ, L.; MANCILLA-VILLA, O. R.; VÁZQUEZ-PEÑA, M. A. Corn grain yield estimation from vegetation indices, canopy cover, plant density, and a neural network using multispectral and rgb images acquired with unmanned aerial vehicles. **Agriculture**, v. 10, n. 7, p. 1-24, 1 jul. 2020.

GITELSON, A.A.; KAUFMAN, Y.J.; STARK, R.; RUNDQUIST, D. Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, v. 80, p. 76-87. 2002.

LOUHAICHI, M.; BORMAN, M. M.; JOHNSON, D. E. Spatially located platform and aerial photography for documentation of grazing impacts on wheat. **Geocarto International**, v. 16, n. 1, p. 65-70, 2001.

LUNA NETO, E. V. DE; SILVA, A. V. DA; SILVA, J. H. B. DA; SILVA, C. M. DA; COSTA, T. R. S.; MIELEZRSKI, F. Spectral vegetation indices in the monitoring of corn (Zea mays L.) submitted to biostimulants. **Nativa**, v. 11, n. 3, p. 323-330, 2023.

SILVA, J. F. **Caracterização dos solos do Instituto Federal do Maranhão, Campus São Raimundo das Mangabeiras, região sul-maranhense**. Dissertação de mestrado. Universidade Estadual Paulista -UNESP. Câmpus de Jaboticabal - SP. 2018.

SOARES, F. C. **Análise da viabilidade da irrigação de precisão na cultura do milho (Zea mays L.)**. 2010. 113 f. Dissertação (Mestrado em Engenharia Agrícola)-Universidade Federal de Santa Maria, Santa Maria, 2010.

WOEBBECKE, D. M., MEYER, G. E., VON BARGEN, K., MORTENSEN, D. A. Color indices for weed identification under various soil, residue and lighting conditions. **Transactions of the ASAE** 38, p. 259-269. 1995.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote sensing of Environment**, v. 8, n. 2, p. 127-150, 1979.

VIAN, A. L.; SANTI, A. L.; AMADO, T. J. C.; CHERUBIN, M. R.; SIMON, D. H.; DAMIAN, J. M.; BREDEMEIER, C. Variabilidade espacial da produtividade de milho irrigado e sua correlação com variáveis explicativas de plantas. **Ciência Rural**, v. 46, n. 3, p. 464-471, 2016.

VARIABILIDADE ESPACIAL DE ATRIBUTOS QUÍMICOS DO SOLO NA PRODUÇÃO DE PASTAGEM EM SISTEMA DE INTEGRAÇÃO-PECUÁRIO-FLORESTA

DIEGO JORGE DA SILVA [1]; ROBERTO BARROS AGUIAR [1]; RODRIGO DE SOUZA PINHEIRO [1]; CLEMESON CARDOSO VALE [2]; MIGUEL JULIO MACHADO GUIMARÃES [3]

[1]Graduando em Agronomia. BR-230, São Raimundo das Mangabeiras - MA, 65840-000. Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, São Raimundo das Mangabeiras ? MA; [2]Engº Agrônomo, Mestre em ciência animal, Professor. BR-230, São Raimundo das Mangabeiras - MA, 65840-000. Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, São Raimundo das Mangabeiras ? MA; [3]Engº Agrônomo, Doutor em Engenharia Agrícola, Professor. BR-230, São Raimundo das Mangabeiras - MA, 65840-000. Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, São Raimundo das Mangabeiras ? MA

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A compreensão de atributos específicos do solo, correlacionados com a resposta em parâmetros de produtividade da pastagem, oferece a oportunidade de aplicação de insumos de maneira racional, localizada e individualizada. Portanto, o objetivo deste trabalho foi avaliar a variabilidade espacial dos atributos químicos do solo e da produção vegetal das pastagens, compreendendo por sua a dinâmica espacial da fertilidade do solo no cerrado sul maranhense. O estudo foi desenvolvido no sistema Integração-Pecuária-Floresta, situado nas dependências do Instituto Federal do Maranhão, Campus São Raimundo das Mangabeiras, (Maranhão), onde foram instalados 18 pontos de amostragem para coleta dos dados químicos de solo e da produtividade do capim Marandu. Os atributos químicos estudados foram: pH, matéria orgânica (MO), fósforo (P), potássio (K), cálcio (Ca), magnésio (Mg), H+Al, V%, m%, CTC e SB. A análise inicial dos dados empregou técnicas de estatística descritiva para identificar os principais parâmetros estatísticos (média, variância, desvio padrão, coeficiente de variação, assimetria e curtose). Em seguida, a análise foi aprofundada por meio de ferramentas de geoestatística, proporcionando uma abordagem mais detalhada para a compreensão da distribuição espacial e padrões variáveis dos dados. Esse processo combinado permitiu uma análise abrangente e robusta, integrando aspectos descritivos e espaciais na interpretação dos resultados obtidos**.**

PALAVRAS-CHAVE: Variabilidade espacial; Geoestatística; Manejo do solo

ABSTRACT

Understanding specific soil attributes, correlated with the response in pasture productivity parameters, offers the opportunity to apply inputs in a rational, localized and individualized way. Therefore, the aim of this study was to evaluate the spatial variability of soil chemical attributes and pasture crop production, thereby understanding the spatial dynamics of soil fertility in the cerrado of southern Maranhão. The study was carried out in the Livestock-Forest Integration system, located on the premises of the Federal Institute of Maranhão, Campus São Raimundo das Mangabeiras, (Maranhão), where 18 sampling points were installed to collect soil chemical data and Marandu grass productivity. The chemical attributes studied were: pH, organic matter (OM), phosphorus (P), potassium (K), calcium (Ca), magnesium (Mg), H+Al, V%, m%, CTC and SB. The initial data analysis used descriptive statistical techniques to identify the main statistical parameters (mean, variance, standard deviation, coefficient of variation, asymmetry and kurtosis). The analysis was then further developed using geostatistical tools, providing a more detailed approach to understanding the spatial distribution and variable patterns of the data. This combined process allowed for a comprehensive and robust analysis, integrating descriptive and spatial aspects in the interpretation of the results obtained.

KEYWORDS: ;;

INTRODUÇÃO

Na busca pela sustentabilidade dos sistemas de produção, a integração-pecuária-floresta ou IPF, surgiu como alternativa para aumentar a produtividade e suprir as necessidades de alimentos e matérias-primas necessárias à sobrevivência humana. Isso é regulado por todo o sistema para proporcionar melhor condicionamento físico do solo, acúmulo de matéria orgânica, permitindo maior retenção de água das chuvas e inviabilizando processos erosivos (SILVA et al.,2020).

A falta de conhecimento do produtor rural sobre a variabilidade dos atributos químicos, físicos e biológicos do solo na sua área de plantio, contribui perpetuamente para grandes perdas econômicas, social e ecológica, como poluição dos lençóis freáticos pelo excesso de fertilizante aplicados no solo sem conhecer as necessidades reais das plantas em relação ao seu suprimento natural oriundo do solo. Com isso, a aplicação de tecnologias geoespaciais, como sistema de posicionamento global (GPS) e geoestatística, tem se feito muito presente atualmente nas dinâmicas de eficiência do sistema produtivo (GEBBERS; ADAMCHUK, 2010), que concomitantemente ao associar metodologias específicas de manejo possibilitam intensificar as unidades produtivas.

OBJETIVOS

Com isso, o objetivo desse trabalho foi avaliar a variabilidade espacial dos atributos químicos do solo, bem como a influência na produção de biomassa do capim Brachiaria brizantha cv. Marandu em um sistema integrado de pastagem floresta no cerrado sul maranhense.

MATERIAL E MÉTODOS

A área de estudo está localizada no sistema Integração Pecuária Floresta (IPF), situado nas dependências do Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, Campus São Raimundo das Mangabeiras. A região apresenta clima do tipo Aw quente com estação seca no inverno e úmida no verão, tendo solo predominante Latossolo Vermelho-Amarelo distrófico (SILVA, 2018). A área experimento do Sistema IPF encontra-se estabelecida há três anos em uma área de 1140 m² (38 m x 30 m) contendo como pastagem o capim marandu (*Brachiaria brizantha*) e Acácia (*Acacia mangium*) como componente arbóreo dispostos em renques espaçados em 10 m e de linhas duplas de 10 m x 1,50 m x 2, 0 m.

O experimento foi realizado em três blocos de 300 m² cada, divididos em seis parcelas de 10 m x 5,0 m. O objetivo era medir o desenvolvimento da pastagem após 15, 30 e 45 dias do rebaixamento da mesma para uniformização. A produção de biomassa (massa verde) foi avaliada utilizando um quadrante de 1,0 x 1,0 m que foi lançados aleatoriamente no interior das parcelas de 10 m x 5 m. O corte foi realizado a uma altura de 0,15 m, que é a altura de saída do pastejo dos animais. Posteriormente, o material coletado foi pesado com o auxílio de uma balança de precisão a qual determinou a matéria fresca (MF) da forragem.

Na determinação dos atributos químicos foram coletadas amostras de solos deformadas, sendo escolhidos aleatoriamente em cinco pontos de amostragem em cada parcelas onde foram coletadas amostras simples na profundidade de 0,0 a 0,20 m, resultando em uma amostra composta por parcela, totalizando 18 amostras composta de solo. No ponto da coleta das amostras simples, a superfície do solo foi exposta, removendo-se restos vegetais graúdos, contudo, sem remover intensamente a camada superficial do solo. Posteriormente as amostras foram homogeneizadas em baldes dando origem as amostras compostas que foram colocados em sacos plásticos, identificadas e encaminhadas ao laboratório para análise.

Para avaliar a variabilidade espacial das variáveis em questão, os resultados foram submetidos a métodos geoestatísticos, conforme delineado por Vieira (2000), com base na premissa da estacionaridade da hipótese intrínseca. Antes disso, os dados foram submetidos a análises estatísticas descritivas, onde foram calculados valores mínimo, máximo, média, desvio padrão, além dos coeficientes de variação (CV), assimetria e curtose. Foi realizada uma análise de correlação de Pearson para avaliar o grau de associação dos atributos químicos do solo com a produção de massa fresca da *Brachiaria brizantha cv*. Marandu na área de estudo. Para prever valores dos atributos químicos em regiões sem amostragem e criar mapas, foi adotado o método de Ponderação pelo Inverso da Distância (IDW).

RESULTADOS E DISCUSSÃO

Com relação aos resultados da análise exploratória dos valores encontrados para os atributos químicos (MO, pH, P, K, Ca, Mg, H+Al, CTC, V% e m%), foi observado a ocorrência de valores de assimetria negativa para os atributos Al^{3+} e V%, indicando que, nestes casos, houve tendência para concentração de valores maiores que a média. A maioria dos atributos apresentou assimetria positiva, com mediana menor que a média, mostrando, assim, a tendência para concentração de valores menores que a média. A assimetria e a curtose são medidas que nos ajudam a entender a distribuição dos valores analisados. Elas nos indicam se os dados têm uma distribuição simétrica ou não, sendo desejável que fiquem próximos a um valor central de zero (Cortez et al., 2011). Quase metade dos atributos apresentou distribuição de frequência platicúrtica, ou seja, com curtose negativa, indicando maior variabilidade.

Durante a análise dos dados, verificou-se também, que a média e a mediana apresentaram valores similares para metade dos atributos, o que indica uma distribuição normal dos dados. Mesmo para os atributos que apresentaram pequenos desvios em relação à distribuição normal, tanto em relação à assimetria quanto à curtose. Azevedo (2014) observou que a normalidade dos dados não é uma condição necessária para a aplicação das técnicas de geoestatística. Sendo assim, Gonçalves et al. (2011) afirmam que a análise exploratória dos dados permite considerar essas distribuições como suficientemente simétricas para o estudo geoestatístico.

Tabela 1 - Estatística descritiva dos atributos químicos do solo, em sistema integrado, na profundidade de 0,0-0,2 m.

Atributos	$\bar{X}$	Md	S	Valores		Coeficientes		
				Mín	Máx	Cv	Cs	Ck
pH (caCl)	4,455556	4,4	0,188562	4,2	4,8	4,232061	0,85057	-0,26502
MO (g/kg)	12,08889	12,05	2,363171	7,3	17,6	19,54829	0,439655	0,906982
P (mg/dm-³)	3,3889	3,2	0,6781	2,7	5	20,011	1,2148	0,7774
K^+ (cmolc dm-³)	0,097	0,08	0,053	0,04	0,23	54,97	1,635	2,195
Ca^{2+} (cmolc dm-³)	0,94	0,91	0,24	0,62	1,46	25,9	0,63	-0,55
Mg^{2+}(cmolc dm-³)	0,57	0,57	0,1	0,41	0,78	18,1	0,27	-0,69
Al^{3+} (cmolc dm-³)	0,18	0,19	0,11	0	0,42	58,5	-0,09	0,93
H+Al (cmolc dm-³)	2,803	2,825	0,782	1,77	4,65	27,9	0,583	0,106
SB (cmolc dm-³)	1,61	1,52	0,31	1,22	2,25	19,3	0,68	-0,78
CTC (cmolc dm-³)	4,41	4,245	0,744	3,1	6,41	16,87	0,867	1,978
V (%)	37,28	34,7	8,99	26,2	54,2	24,11	0,576	-0,89
m (%)	10,41	12,15	5,705	0	19,21	54,79	-0,71	0,065

$\bar{X}$ = média; Md = mediana; s = desvio-padrão; Máx. = máximo; Mín. = mínimo; CV = coeficiente de variação; Cs = coeficiente de assimetria; Ck = coeficiente de curtose

Ao analisar os atributos, constatou-se que a maioria deles apresentou baixos níveis de fertilidade do solo na profundidade de 0,0-0,2m. No entanto, alguns atributos mostraram uma ampla amplitude de valores na área, como o Ca^{2+}, que variou de 0,62 a 1.46 cmol/dm^3 e a MO 7,3 a 17,6 g/kg. Essa variação indica que, em alguns casos, o uso da média mascara os sítios com valores relativamente altos na área, conforme observado por Azevedo (2014) em um estudo realizado em pastagem.

Observou-se o maior coeficiente de variação (CV%) para o atributo Al^{3+} (58,5%) e o menor, para o pH (4,23%). De acordo com Davis et al. (2015), o menor CV encontrado para o pH é por ser este uma função logarítmica e, assim, apresenta, naturalmente, pequena variação.

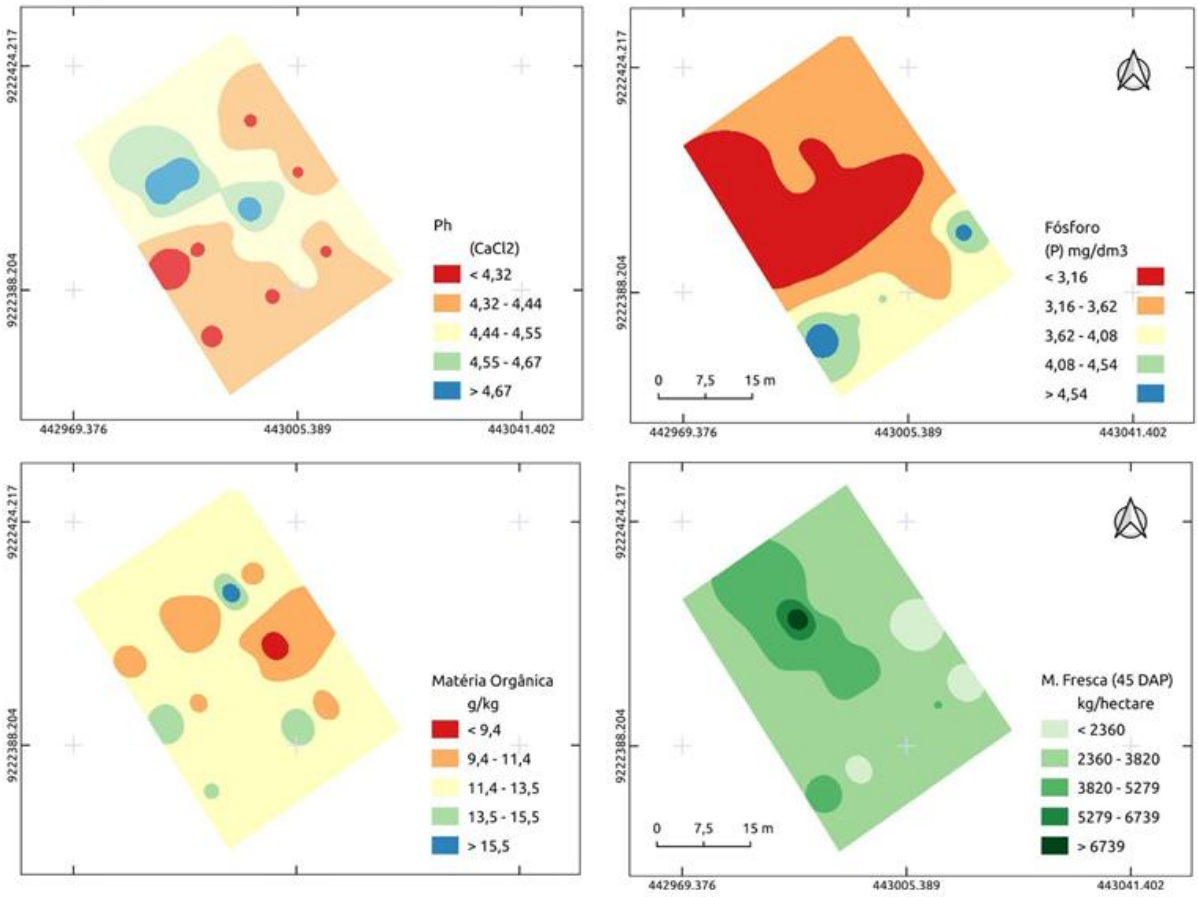


FIGURA 1. Distribuição espacial do Ph (CaCl2), do fósforo (mg/dm^3), da matéria orgânica(g/kg) e da matéria fresca (kg/$há^{-1}$) da forragem.

A heterogeneidade dos atributos químicos do solo está relacionada à variação espacial dessas características em uma área. Isso significa que diferentes áreas do solo podem apresentar diferentes níveis de nutrientes, acidez, fertilidade, entre outros fatores. Essa variação espacial nos atributos químicos do solo pode influenciar diretamente a produtividade da pastagem. De acordo com os resultados obtidos, verificou-se que o período compreendido nos 45 dias subsequentes a padronização da pastagem na área experimental apresentou uma proporção significativamente maior de massa fresca em comparação aos outros períodos analisados.

A qualidade de produção de matéria fresca e seca de uma forrageira é altamente influenciada pelas condições ambientais a que a planta está exposta e pelos métodos de manejo utilizados. Portanto, fatores como temperatura, luz, disponibilidade de água e nutrientes determinam o potencial fotossintético da copa das plantas, o que implica alterações na área foliar e na capacidade fotossintética da mesma (MARCELINO et al., 2006). Este fato leva-nos a crer que as condições

ambientais e a baixa fertilidade do solo também afetam a produção de espécies consideradas mais adaptadas.

Segundo o manual de recomendação de adubação, Manual Do Cerrado, o P variou de muito baixo a baixo na área do experimento. O fósforo, quando em doses insuficientes no solo é considerado um dos nutrientes que mais limita a produção da biomassa de forragem (REZENDE et al., 2011). Este nutriente desempenha um papel importante devido à intensa atividade do meristema que ocorre durante os estágios iniciais da planta com desenvolvimento da raiz, perfilhamento e liberação do estolão. Além disso, o P é de fundamental importância durante a divisão celular devido à sua estrutura funcional nos ácidos nucléicos (Cantarutti et al., 2002). Os valores críticos de P para o estabelecimento de B. decumbens, B. Brizantha e Panicum Maximum foram estudados por Corrêa (1991). O autor relata que existem diferenças consideráveis nas necessidades das gramíneas estudadas em condições de campo, onde a B. decumbens demostrou diferença significativas em relação com as necessidades mais baixas de P para seu estabelecimento. Em seguida, por ordem de demanda, vieram o Capim-colonião e a B. brizantha sendo mais exigentes.

CONCLUSÃO

A estrutura de dependência espacial, para os atributos, foi caracterizada na área de estudo, apresentando a necessidade de remoção de tendência para ph, p, e m%.

A confecção dos mapas, para cada atributo, permitiu visualizar a sua distribuição espacial na área, fato que não ocorre quando se utiliza somente análise tradicional sem levar em conta as zonas de manejos específicas.

A relação entre um mapa de produção de pastagem e a heterogeneidade dos atributos químicos do solo permite identificar áreas com maior e menor produtividade da pastagem, e possibilita tomar ações para melhorar a produção por meio de correções nos atributos químicos do solo.

AGRADECIMENTOS

Ao Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, Campus São Raimundo das Mangabeiras pelo apoio através da concessão da bolsa de iniciação científica.

REFERÊNCIAS

AZEVEDO, E.C. **Uso da geoestatística e de recursos de geoprocessamento no diagnóstico da degradação de um solo argiloso sob pastagem no estado de Mato Grosso**. 2013. Tese (Doutorado)-Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, Campinas, 2014.

ANTARUTTI, R.B.; BODDEY, R.M. Transferência de nitrogênio das leguminosas para as gramíneas. In: **simpósio internacional sobre produção animal em pastejo**, 1997, Viçosa, MG.

CORTEZ, J.W.; FURLANI, C.E.A.; VIGNA, G.P.; BORSATTO, E.A.; SILVA, R.P. **Desempenho do trator agrícola no manejo da cultura de cobertura e pressão de inflação do pneu da semeadora.** *Engenharia Agrícola*, Jaboticabal, v.29, n.1, p.72-80, 2009.

GEBBERS, R.; ADAMCHUK, V. I**. Precision Agriculture and food security**. Science, v. 327, p. 828-831, 2010.

GONÇALVES, A.C.A. et al. Análises exploratória e geoestatística da variabilidade de propriedades físicas de um Argissolo Vermelho, **Acta Sci. Agron**., Maringá, v. 23, n. 5, p. 1149-1157, 2011.

INAMASU, R. Y. et al**. Agricultura de precisão para a sustentabilidade de sistemas produtivos do agronegócio brasileiro**. In: Inamasu, R.Y. et al. (org.). Agricultura de precisão: um novo olhar. São Carlos: Embrapa Instrumentação, 2011. p. 14-26.

MARCELINO, e. v.; nunes, l. h.; kobiyama, m. mapeamento de risco de desastres naturais do estado de santa catarina. **caminhos de geografia**, uberlândia, v. 7, n. 17, p. 72-84, 2006.

REZENDE, F. A. C. et. al. Variabilidade espacial dos teores de macronutrientes em Latossolos sob sistema plantio direto.**Revista Brasileira de Ciência do Solo**, v.34, p.389-400,2010.

Silva, R. C.; Pereira, J. M.; Araújo, Q. R.; Pires, A. J. V.;Del Rei, A. J. Alterações nas propriedades químicas efísicas de um Chernossolo com diferentes coberturasvegetais. **Revista Brasileira de Ciência do Solo**, v.31,p.101-107, 2007.

Vieira, S. R. **Geoestatística em estudos de variabilidade espacial do solo**. In: Novais, R. F.; Alvarez V., V. H.; Schaefer, C.E. (ed.) Tópicos em ciências do solo. Viçosa: Sociedade Brasileira de Ciência do Solo, 2000. p.1-54.

UTILIZANDO IMAGENS RGB E ALGORITMOS DE CLASSIFICAÇÃO PARA DIFERENCIAR SOLOS VISANDO VITICULTURA DE PRECISÃO

Adão Felipe dos Santos [1]; Octavio Pereira Costa [2]; Matheus Ardigueri [2]; Wender Henrique Barbosa da Silva [2]; Pedro Maranha Peche [1]

[1]Docente. Trevo Rotatório Professor Edmir Sá Santos Universidade Federal de, Lavras - MG, 37203-202. Universidade Federal de Lavras; [2]bolsista. Trevo Rotatório Professor Edmir Sá Santos Universidade Federal de, Lavras - MG, 37203-202. Universidade Federal de Lavras

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Este estudo explora a aplicação de imagens RGB capturadas por drones para detectar variações de solo dentro de um talhão cultivado com uva e bem como a possibilidade de utilizar essas imagens para dar início à gestão diferenciada por zonas de manejo. Dessa forma, objetivou-se verificar a qualidade da classificação de imagens RGB, e a possibilidade em distinguir de forma eficaz tipos de solo com base em variações de cor. Os algoritmos utilizados para a classificação foram o K-vizinhos mais próximos (KNN) e Random Forest (RF), os quais apresentaram precisão similar na classificação de imagens RGB coletadas por UAV. A utilização do índice VIgreen destacou o desempenho do RF em relação ao KNN na discriminação de classes de solo, atribuído à sua capacidade de lidar com múltiplas variáveis. No entanto, depender exclusivamente do VIgreen com uma câmera RGB pode não oferecer a estratégia mais otimizada para a diferenciação precisa de solo na viticultura. Os resultados apontaram que foi posível classificar a imagem e diferenciar as possiveis classes de solo com ambos os algoritimos. Entretanto, explorar metodologias alternativas e outros índices de vegetação, especialmente provenientes de câmeras multiespectrais, pode aprimorar as técnicas de gestão de vinícolas e, consequentemente, melhorar a qualidade do vinho por meio de terroir.

PALAVRAS-CHAVE: manejo do vinhedo; terroir; classificação do solo

ABSTRACT

This study explores the application of RGB images captured by drones to detect soil variations within a vineyard as well as the possibility of using these images to initiate zone-specific management. The objective was to verify the quality of RGB image classification and the ability to distinguish soil types based on color variations effectively. The algorithms used for classification were K-nearest neighbors (KNN) and Random Forest (RF), which showed similar accuracy in classifying RGB images collected by UAVs. The use of the VIgreen index highlighted the performance of RF in relation to KNN in the discrimination of soil classes, attributed to its ability to deal with multiple variables. However, relying exclusively on VIgreen with an RGB camera may not offer the most optimized strategy for accurate soil differentiation in viticulture. The results showed that it was possible to classify the image and differentiate the possible soil classes with both algorithms. However, exploring alternative methodologies and other vegetation indices, especially from multispectral cameras, can improve winery management techniques and, consequently, improve wine quality through terroir.

KEYWORDS: vineyard management; terroir; soil classification

INTRODUÇÃO

O sensoriamento remoto revolucionou os estudos agrícolas ao fornecer insights valiosos sobre diversos aspectos do manejo de culturas e do uso da terra. Em particular, o uso de imagens obtidas remotamente mostrou-se eficaz na localização, delineamento e classificação de áreas agrícolas

[Giovos et al. 2021]. A aplicação dessas tecnologias no campo do manejo de vinhas testemunhou avanços notáveis, possibilitando um monitoramento e controle mais eficientes do crescimento das videiras. Com a disponibilidade de dados detalhados e de alta resolução, os gestores de vinícolas agora têm a oportunidade de obter uma compreensão abrangente da variabilidade espacial [Matese e Di Gennaro, 2018]. Ao aproveitar essas informações, eles podem tomar decisões informadas e implementar estratégias direcionadas para otimizar a produção de uvas e aprimorar a eficiência geral do manejo.

Embora a Viticultura de Precisão (PV) englobe diversas tecnologias, a combinação de imagens de drones e algoritmos de classificação emerge como uma abordagem promissora para o manejo da cultura da uva. Essa metodologia de ponta possui um potencial significativo não apenas para aprimorar práticas vitícolas, mas também para garantir a produção de vinhos de alta qualidade que reflitam autenticamente as características únicas do terroir [Vaudour et al. 2015]. Ao estabelecer uma base para práticas sustentáveis e precisas, essa integração torna a viticultura mais eficiente em termos de recursos, economicamente viável e ambientalmente responsável.

Neste estudo, exploramos a aplicação de imagens RGB obtidas a partir de imagens de drones para identificar diferenças de solo em um talhão de uva. Nossa hipótese é baseada em que o uso de imagens RGB, juntamente com algoritmos de classificação adequados, fornecerá informações valiosas para diferenciar solos com base em variações de cor e identificar possíveis locais para se delinear zonas de manejo com base na variabilidade do solo. Com isso, os gestores podem adaptar suas práticas e intervenções às condições específicas do solo, otimizando assim a saúde das videiras e a qualidade das uvas no Sul do Estado de Minas Gerais.

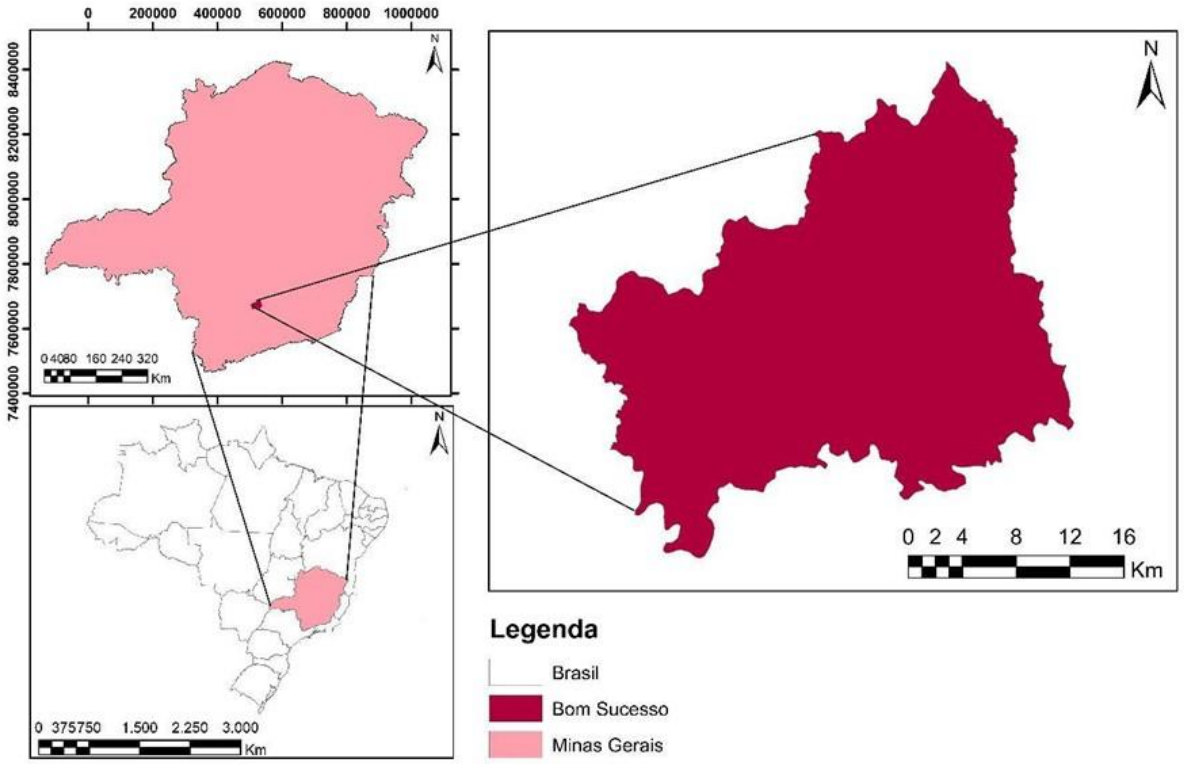
OBJETIVOS

Neste estudo, exploramos a aplicação de imagens RGB obtidas a partir de imagens de UAV para identificar diferenças de solo em um talhão de uva. Nossa hipótese é baseada em que o uso de imagens RGB, juntamente com algoritmos de classificação adequados, fornecerá informações valiosas para diferenciar solos com base em variações de cor e identificar possíveis locais para se delinear zonas de manejo com base na variabilidade do solo.

MATERIAL E MÉTODOS

O estudo foi realizado em uma vinícola localizada no município de Bom Sucesso, Minas Gerais, Brasil (Figura 1). A área de plantio de uvas está situada a uma altitude de 952 m, com um clima mesotérmico classificado como Cwb de acordo com o sistema de classificação climática de Köppen. A precipitação média anual é de 1598 mm, e a temperatura média anual é de 19,3°C. Os meses de inverno são secos e frios, enquanto os meses de verão são chuvosos, com temperaturas que chegam a ultrapassar os 22°C [VILELA e RAMALHO 1979].

Os solos na região possuem fertilidade de média a baixa, com texturas médias/argilosas e argilosas, classificados em sua maioria como Latossolos Vermelho-Amarelo de acordo com o levantamento de solos de intensidade média na zona de Campos das Vertentes de Minas Gerais [EMBRAPA 2006].



Localização do campo de produção de uvas utilizado neste estudo.

A aquisição e processamento das imagens aéreas foram realizados utilizando um DJI Phantom 4 Advanced. A Aeronave Remotamente Pilotada (ARP) estava equipado com um sistema de posicionamento GPS/GLONASS padrão e um sensor CMOS de 1 polegada capaz de capturar vídeos com resoluções de até 4.096 × 2.160 pixels a 60 quadros por segundo, assim como fotos com resolução máxima de 20 megapixels. Para planejar o voo e coletar imagens, o software gratuito Pix4DCapture foi instalado em um sistema iOS. A ARP foi operada a uma altitude de 120 metros (resolução espacial de 5x5cm), uma velocidade de 5 m/s e com sobreposição de 75% em todos os lados para garantir uma cobertura abrangente.

As imagens capturadas foram processadas usando o Pix4D mapper.

Para gerar o ortomosaico, as imagens passaram por uma série de etapas utilizando o software Pix4D mapper. Primeiramente, as fotos foram alinhadas usando o processo de fototriangulação, que resultou na geração de uma nuvem de pontos esparsa. Essa nuvem de pontos determinou o sistema de coordenadas do terreno (Etapa 1). Posteriormente, na Etapa 2, a nuvem de pontos esparsa da etapa anterior foi densificada, resultando em uma representação mais detalhada da área mapeada. A nova nuvem de pontos densificada foi então referenciada ao sistema de coordenadas local WGS 84 Zona 23S. Na Etapa 3, um modelo tridimensional preciso foi construído para representar com precisão o terreno mapeado. Esse modelo facilitou a criação de um modelo digital de superfície (MDS). Ao filtrar os pontos de solo da nuvem de pontos, foi obtido um modelo digital de terreno (MDT), que proporcionou uma visualização do terreno sem obstruções. Avançando para a Etapa 4, a textura obtida da etapa anterior foi aplicada ao modelo, melhorando a aparência visual e possibilitando uma melhor distinção entre diferentes objetos dentro do modelo. Na Etapa 5, o MDT foi gerado, resultando em representações raster bidimensionais do MDS e do MDT. Finalmente, na Etapa 6, o ortomosaico foi produzido, concluindo o fluxo de processamento. O ortomosaico representa uma imagem aérea corrigida e geometricamente precisa da área mapeada.

Depois de obter o ortomosaico, a área de estudo foi subdividida em segmentos representando cinco tipos distintos de solo e uma classe de vegetação, determinada por classificação visual. Esse processo de segmentação utilizou a imagem RGB para identificar diferenças visíveis. Após esse processo, de realizar a classificação supervisionada de imagens, empregamos dois algoritmos: o método de aprendizado supervisionado conhecido como K-Nearest Neighbors (K-NN) e o método de aprendizado Random Forest (RF). Esses algoritmos foram aplicados com o suporte do plugin de classificação Dzetsaka, integrado ao ambiente QGIS. Os algoritimos foram aplicados em duas situações, a primeira na imagem RGB bruta e posteriormente na imagem com o Indice de vegetação VIgreen calculado.

Para avaliar a precisão dos algoritmos de classificação, foi gerada uma matriz de confusão para as imagens classificadas usando amostras selecionadas aleatoriamente e estratificadas. As amostras foram selecionadas proporcionalmente ao tamanho das classes obtidas na etapa 2. Um total de seis classes de classificação foram utilizadas para todas as imagens, com um erro padrão de 0,005: sendo as classes definidas como: 1 - Solo 1; 2 - Solo 2; 3 - Solo 3; 4 - Solo 4; 5 - Solo 5; e 6 - Vegetação. Esse processo resultou em 397 amostras aleatórias por classe e então essas informações foram inseridas no pug-in AcATaMa para proceder a classificação supervisionada e gerar os índices Kappa e de acurácia.

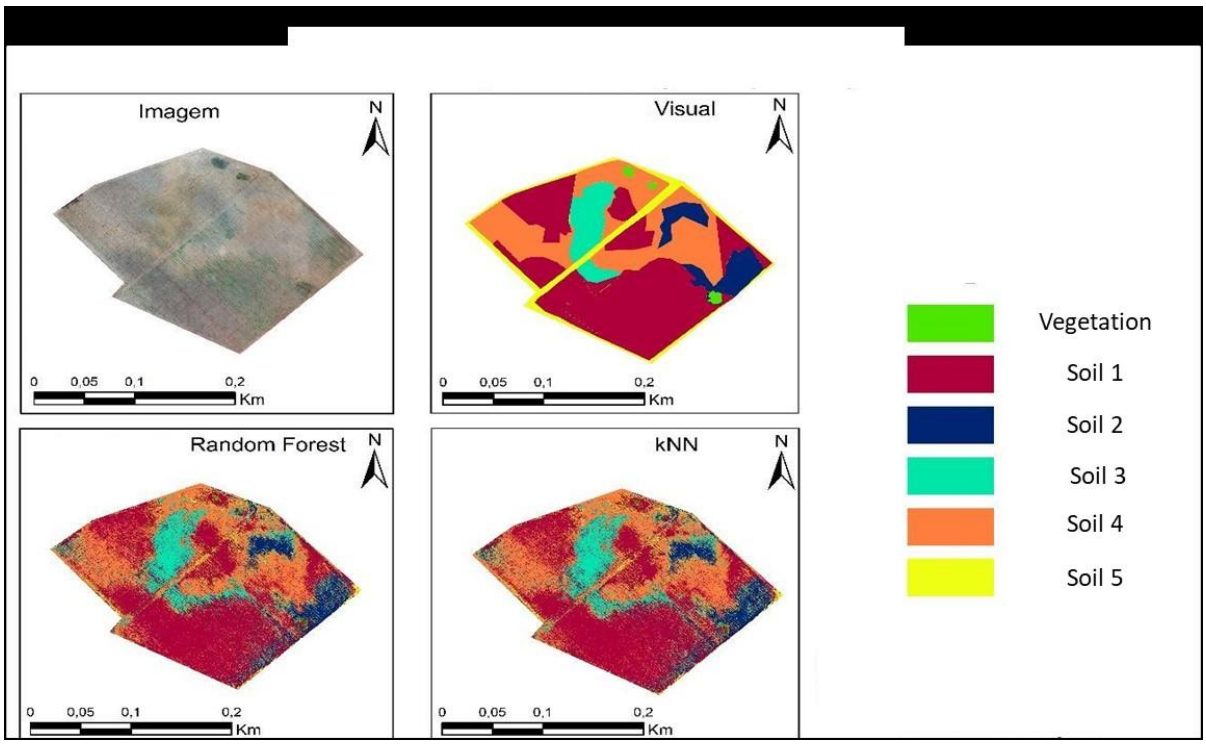
RESULTADOS E DISCUSSÃO

Após aplicar os algoritmos de classificação supervisionada K-Nearest Neighbors (KNN) e Random Forest (RF) às imagens de drone, foram obtidos resultados de acurácia e índice Kappa notavelmente similares (Tabela 1). Os valores de acurácia e índice Kappa foram de 0,6259 e 0,4661 para RF e 0,6205 e 0,4445 para KNN, respectivamente quando se utilizou somente as imagens RGB. Essa similaridade nos resultados sugere que ambos os algoritmos foram eficazes na classificação das imagens e na determinação de diferentes classes de interesse, como tipos de solo e vegetação.

Tabela 1. Resultados das imagens utilizadas e desempenho dos algoritmos em cada uma

	RF		KNN	
	Acurácia	Kappa	Acurácia	Kappa
RGB	0,6259	0,4661	0,6205	0,4445
VIGreen	0,5398	0,3678	0,1980	0,0221

A similaridade na acurácia dos algoritmos KNN e RF sugere que ambos são adequados para a classificação de imagens de drone utilizando imagens RGB e fornecem informações confiáveis sobre a distribuição de diferentes classes (Figura 2). O KNN é um algoritmo de aprendizado supervisionado que opera com base na proximidade entre pontos de dados, classificando uma nova instância de acordo com a classe da maioria dos seus vizinhos mais próximos. Por outro lado, o RF é um método baseado em árvores de decisão que utiliza múltiplas árvores para gerar uma previsão mais robusta e precisa. Ambos os algoritmos demonstraram desempenho consistente, o que é crucial para a aplicação precisa da Viticultura de Precisão (PV).



Ortomosaicos coletados por UAV e imagens RGB. Ortomosaico processado (superior esquerdo), classificação visual (superior direito), classificação RF (inferior esquerdo) e classificação KNN (inferior direito).

Essa precisão na classificação não apenas possibilita a implementação de práticas mais direcionadas e personalizadas para cada zona específica, como a aplicação focada de insumos e o uso eficiente de irrigação, mas também é fundamental para a determinação precisa de zonas de manejo em propriedades rurais. A capacidade do KNN de identificar padrões com base na proximidade dos dados é complementada pela capacidade do RF de criar modelos complexos e capturar relações não lineares entre as variáveis, resultando em uma abordagem robusta para a análise de imagens de drone em aplicações agrícolas.

A PV, quando apoiada por imagens de drone e técnicas de classificação supervisionada como KNN e RF, possibilita um gerenciamento mais inteligente e eficiente dos recursos, reduzindo o desperdício e aumentando a qualidade e produtividade das uvas. Além disso, o uso dessas tecnologias proporciona uma compreensão mais profunda do terroir, permitindo que viticultores entendam melhor as especificidades do ambiente de cultivo e sua influência na qualidade do vinho produzido [Vaudour et al., 2015].

Quando o índice de vegetação VIgreen foi aplicado na classificação, o algoritmo KNN não alcançou uma acurácia satisfatória, enquanto o algoritmo Random Forest (RF) foi capaz de classificar e delinear as diferenças entre as classes de solo de forma mais eficiente (Figura 3). Uma das principais razões para esse resultado pode estar associada ao fato de que o VIgreen, como um índice de vegetação, é mais sensível para detectar a vegetação e seu vigor. Como resultado, pode ser menos eficaz na discriminação entre diferentes tipos de solo, já que seu foco está na resposta espectral das plantas, e não nas características do solo. Portanto, o KNN pode enfrentar dificuldades em usar efetivamente o VIgreen para classificar as classes de solo.

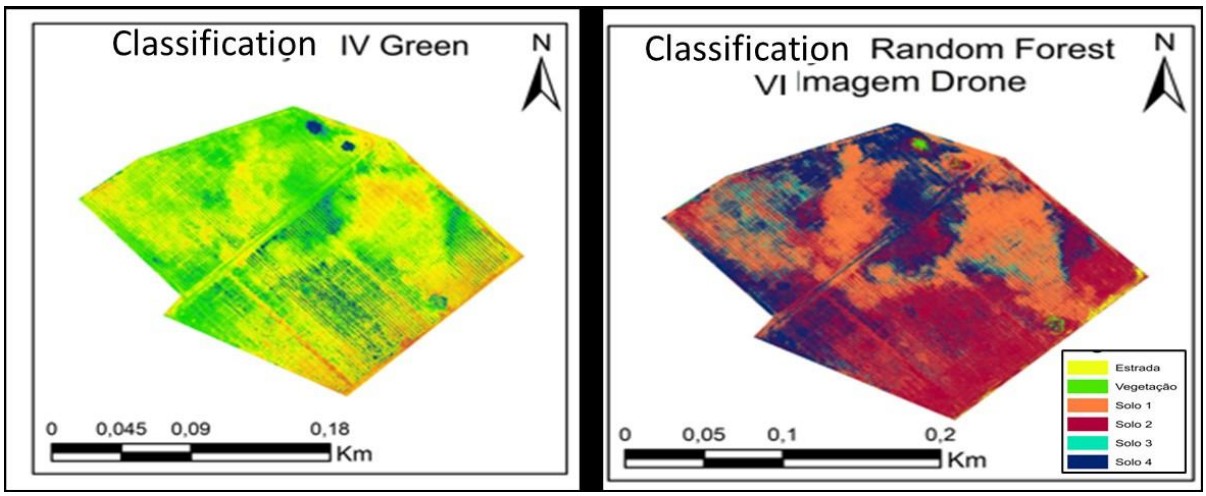


Figura 3 - Ortomosaico com VIgreen (à esquerda) e classificação usando RF após calculo do VIgreen (à direita).

Por outro lado, vale destacar que o Random Forest é renomado por sua robustez e capacidade de lidar com múltiplas variáveis e interações complexas entre elas. Ele é mais adequado para classificar dados com múltiplas dimensões, o que pode explicar seu desempenho superior em delinear as diferenças entre as classes de solo usando o VIgreen. Resultados diferentes foram encontrados ao utilizar índices espectrais como dados de entrada auxiliares em métodos de classificação, onde o VI melhorou o desempenho dos modelos em comparação com o uso apenas dos canais R, G e B [Olmedo et al., 2017]. Apesar dessa diferença, esses autores encontraram uma classificação semelhante usando o algoritmo RF com um aumento de 8% na acurácia geral, destacando a importância de utilizar informações espectrais mais abrangentes para tarefas de classificação.

Esses resultados destacam a importância de escolher algoritmos robustos e considerar informações espectrais adicionais para obter resultados mais precisos e confiáveis na classificação de imagens de drone para aplicações agrícolas, como na viticultura de precisão.

CONCLUSÃO

Os algoritimos de classificação tiveram performances similares na classificação das imagens. Isso significa que foi possível delimitar as diferenças na coloração de solo e consequentemente será possível aprofundar os estudos para implementação de zonas de manejo com amostragem direcionadas de perfil do solo.

AGRADECIMENTOS

À Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), ao Programa de Pós-graduação em Fitotecnia da UFLA e a Vinícola Alma Gerais.

REFERÊNCIAS

Giovos, R., Tassopoulos, D., Kalivas, D., Lougkos, N., and Priovolou, A. (2021). Remote Sensing Vegetation Indices in Viticulture: A Critical Review. **Agriculture**, 11(5), 457. https://doi.org/10.3390/agriculture11050457

Matese, A., and Di Gennaro, S. F. (2018). Practical Applications of a Multisensor UAV Platform Based on Multispectral, Thermal and RGB High Resolution Images in Precision Viticulture. **Agriculture**, 8(7), 116. https://doi.org/10.3390/agriculture8070116

Motohka, T., Nasahara, K.N., Oguma, H., Tsuchida, S., 2010. Applicability of Green-red Vegetation Index for Remote Sensing of Vegetation Phenology. **Remote Sensing**, 2(10), pp. 2369-2387

Olmedo, G. F., Ingram, B., Bardeen, M. (2017). Detection and Segmentation of Vine Canopy in Ultra-High Spatial Resolution RGB Imagery Obtained from Unmanned Aerial Vehicle (UAV): A Case Study in a Commercial Vineyard. **Remote Sensing**, 9(3), 268. https://doi.org/10.3390/rs9030268

Vaudour, E., Costantini, E., Jones, G. V., and Mocali, S. (2015) An overview of the recent approaches to terroir functional modelling, footprinting and zoning, **SOIL**, 1, 287-312, https://doi.org/10.5194/soil-1-287-2015

Vilela, E. A., and RAMALHO, M. A. P. (1979) Análises das temperaturas e precipitações pluviométricas de Lavras - MG. **Ciência e prática**. p. 71-79.

QUALIDADE DE SEMEADURA DE ARROZ PRÉ-GERMINADO COM USO DE DRONE

Lidiane Bortoli [1]; Gilvan Moises Bertollo [2]; Matheus Da Silva [1]; Antonio Luis Santi [2]; Stela Kulczynski [2]

[1]Discente. Linha 7 de Setembro, s/n BR 386 Km 40 Frederico Westphalen - RS. Universidade Federal De Santa Maria; [2]Docente. Linha 7 de Setembro, s/n BR 386 Km 40 Frederico Westphalen - RS. Universidade Federal De Santa Maria

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A produção de *Oryza sativa* se estende por vários continentes, sendo a base alimentar de muitas pessoas. A população mundial está aumentando, como isso, o aumento da demanda pelo produto arroz tende a aumentar proporcionalmente. No brasil, existem diversos métodos de cultivos de arroz, predominando, o arroz irrigado. A utilização da tecnologia do drone na cultura do arroz, está ganhando espaço na semeadura de sementes pré-germinadas e para aplicação de fertilizantes. Contudo, requer-se estudos sobre a eficiência operacional, técnicas e viabilidade dessa aplicação. Sendo assim, objetivou-se avaliar os efeitos das diferentes velocidades do rotor do drone na semeadura do arroz pré-germinado. O estudo foi conduzido na Universidade Federal de Santa Maria campus de Frederico Westphalen. Foi utilizado o delineamento inteiramente casualizado com 6 tratamentos (rotação 0, 250, 500, 750, 1000 e 1250 rpm) e 4 repetições. A variedade de arroz utilizado foi o IRGA 424. As avaliações fisiológicas foram realizadas pelo teste de germinação (plântulas normais e anormais, sementes duras e mortas) e de vigor (plântulas normais fortes e fracas, comprimento da área e raiz, massa verde e seca). Os resultados indicaram que, acima de 750rpm afetam a porcentagem de germinação, plantas normais, anormais plântulas e sementes duras e mortas.

PALAVRAS-CHAVE: Germinação; Tecnologia; Eficiência Operacional

ABSTRACT

Oryza sativa production extends across several continents, being the staple food for many people. The world population is increasing, as a result, the increase in demand for rice tends to increase proportionally. In Brazil, there are several methods of rice cultivation, predominantly irrigated rice. The use of drone technology in rice cultivation is gaining ground in sowing pre-germinated seeds and for applying fertilizers. However, studies are required on the operational efficiency, techniques and feasibility of this application. Therefore, the objective was to evaluate the effects of different drone rotor speeds on the sowing of pre-germinated rice. The study was conducted at the Federal University of Santa Maria campus of Frederico Westphalen. A completely randomized design was used with 6 treatments (rotation 0, 250, 500, 750, 1000 and 1250 rpm) and 4 replications. The rice variety used was IRGA 424. Physiological evaluations were carried out using the germination test (normal and abnormal seedlings, hard and dead seeds) and vigor (strong and weak normal seedlings, area and root length, green and dry mass). The results indicated that above 750rpm affect the percentage of germination, normal plants, abnormal seedlings and hard and dead seeds.

KEYWORDS: *Oryza sativa*;

INTRODUÇÃO

O arroz é uma cultura cultivada e consumida na maioria dos continentes, sendo destaque no mundo por sua alta produção global e de grandes áreas de cultivo, além de fazer parte da base alimentar de milhões de pessoas. Com cerca de 161 milhões de hectares produzidos, mundialmente, a partir dessa

cultura, estima-se que a produção deverá dobrar até 2050 (SOSBAI, 2018). Existem alguns métodos de plantio que predominam no estado do Rio Grande do Sul: método sem revolvimento para semeadura imediata que corresponde a 61% das áreas, sistemas convencionais com 30% e sistemas pré-germinados com 9%, segundo levantamento do Instituto Rio Grandense de Arroz (2017). O método pré-germinado utilizando drones surgiu como uma alternativa viável comparados aos sistemas convencionais e pela facilidade de manejo. Neste método, permite que a área possa ser inundada 20 dias antes da semeadura e drenada 3 dias após a semeadura. O uso do drone é recente no cultivo de arroz pré-germinado, sendo importante analisar a sua eficiência técnica e econômica.

OBJETIVOS

Avaliar os efeitos de diferentes velocidades do rotor do drone na semeadura de arroz pré-germinado.

MATERIAL E MÉTODOS

O estudo foi realizado na Universidade Federal de Santa Maria campus de Frederico Westphalen (RS), no laboratório de produção e tecnologia de sementes do curso de agronomia. Utilizou-se a cultivar IRGA424 pré-germinada em processo de submersão por 24horas em temperatura ambiente média de 22ºC. Sequentemente, foi retirada da água e deixado por mais 24horas em temperatura média de 20ºC até chegar ao ponto de agulha, que é o momento fisiológico ideal do arroz pré-germinado a ser levado ao campo. O ponto de agulha é onde o coleóptilo apresenta de 1-2mm de comprimento de acordo com a indicação da RAS (BRASIL, 2009). O experimento foi conduzido a campo, em delineamento inteiramente casualizado, com 4 repetições e 6 tratamentos (testemunha, 250, 500, 750, 1000, 1250 rpm). Utilizou-se um drone modelo DJI Agras T40 com capacidade de carga de 50kg, densidade de 100kg/ha e 2m de altura para a dispersão de sementes pré-germinadas, o rotor do drone permaneceu ligado por cerca de um minuto para alcançar a rotação desejada. Para a dispersão das sementes com o uso do drone, utilizou-se uma lona, após serem coletadas da lona com o auxílio de um pincel e postas em recipientes plásticos identificados e conduzidas ao laboratório de sementes. Em seguida, as sementes foram coletadas para a avaliação da qualidade fisiológica de germinação no papel germitest umedecido com água destilada na proporção de 3 vezes o seu peso, sendo analisada 100 sementes por repetição, totalizando 400 sementes, após, armazenado em BOD a 21ºC por 12horas de fotoperíodo, sendo a primeira e segunda análise realizada no quinto e decimo quarto dia após a semeadura, de acordo com a RAS (BRASIL, 2009). No quinto dia foram contadas sementes que já havia coleóptilos e radículas, e plântulas normais fortes e fracas, comprimento da parte aérea e raiz, peso de massa verde e massa seca (submetidas secagem em estufa em temperatura de 65ºC). Os dados coletados e armazenados foram submetidos a análise ANOVA pelo software Sisvar (FERREIRA,2019) e as medias foram comparadas pelo teste de Tukey a 5% de probabilidade de erro.

RESULTADOS E DISCUSSÃO

Os dados mostraram que houve diferença significativa na germinação de 5 dias e 14 dias, mostrando que a velocidade do rotor afeta essa variável.

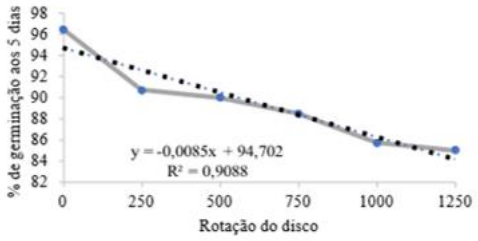
Tabela 1 - Tratamentos, repetições e as diferentes velocidades do rotor em rotações por minuto (RPM) do drone.

Tratamento	Repetições	Velocidade do Rotor (RPM)
Testemunha	4	0

1	4	250
2	4	500
3	4	750
4	4	1000
5	4	1250

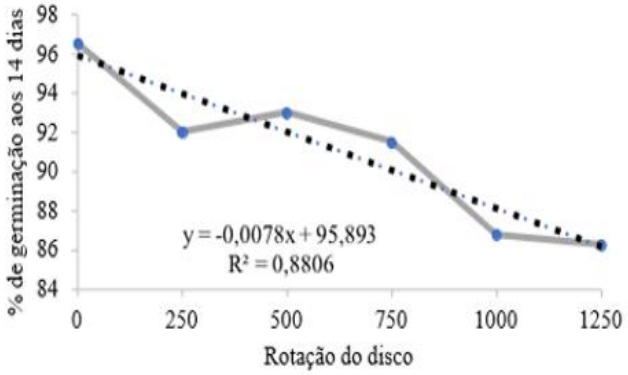
As sementes pré-germinadas não submetidas ao drone, apresentou uma percentagem de 96% de germinação, na coleta de dados do quinto dia, após a qualidade decaiu gradativamente, com o aumento da rotação do disco dispersor de semente em cerca de 10% operando na rotação máxima 1250rpm.

Figura 1 - Porcentagem de Germinação de sementes e arroz pré-germinado em relação a velocidade do rotor do drone aos 5 dias.



Aos 14 dias, a germinação tinha uma taxa de 96% de germinação na contagem final. Segundo Liu (WEI et al.,2022), a taxa de germinação do VANT, aos 14 dias, representou uma percentagem final de 86,2%.

Figura 2 - Porcentagem de germinação de sementes de arroz pré-germinados em relação a velocidade do rotor do drone aos 14 dias.



Em até 750rpm, a germinação representou um porcentual de 90%, a medida que aumenta o rpm, diminui a percentagem de germinação, gradativamente, em função da raiz primaria ser quebrada pelo distribuidor. O número de plântulas diminui também com o aumento da rpm. Observou-se também que na medida que diminuía a velocidade do rotor, diminui a largura de trabalho, diminuindo a eficiência operacional.

CONCLUSÃO

Conclui-se que a porcentagem de germinação e o vigor expresso pela percentagem de plântulas normais germinadas aos 5 dias são afetadas com rotação acima de 750rpm, e o número aumenta em dez vezes de sementes mortas na rotação de 1250rpm.

REFERÊNCIAS

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. Regras para Análise de Sementes. Ministério da Agricultura, Pecuária e Abastecimento. Secretaria de Defesa Agropecuária, 399p. 2009.

FERREIRA, Daniel Furtado. SISVAR: A computer analysis system to fixed effects split plot type designs. Revista Brasileira de Biometria, v. 37, n. 4, p. 529-535, 2019. DOI: https://doi.org/10.28951/rbb.v37i4.450.

IRGA. Safras/Cultivares. Governo do Estado do Rio Grande do Sul, Pecuária e Irrigação. Instituto Rio Grandense do Sul. As 10 cultivares mais plantadas no Rio Grande do Sul. Safra 2017/2018. DOI: https://irga.rs.gov.br/cultivares.

LIU, Wei, et al. Development of UAV-based shot seeding device for rice planting. International Journal of Agricultural and Biological Engineering, v. 15, n. 6, p. 1-7, 2022. DOI: 10.25165/j.ijabe.20221506.7301.

SOSBAI. Arroz irrigado: Recomendações Técnicas da Pesquisa para o Sul do Brasil. Sociedade Sul-Brasileira de Arroz Irrigado, 205 p. 2018.

ANÁLISE DA OCORRÊNCIA DO EXCESSO DE VELOCIDADE DE UM PENETRÔMETRO EM UMA ÁREA DE ARRANQUIO DE CAFÉ POR REGRESSÃO LOGÍSTICA

Rosalra Maria Alves de Morais [1]; Gabriel Araújo e Silva Ferraz [2]; Amara Lana de Abreu [3]; Franck Morais de Oliveira [4]; Aldir Carpes Marques Filho [5]

[1]Bolsista. Campus Universitário - Caixa Postal 3037 - CEP 37200-000 - Lavras - MG - Brasil. Universidade Federal de Lavras; [2]Docente. Campus Universitário - Caixa Postal 3037 - CEP 37200-000 - Lavras - MG - Brasil. Universidade Federal de Lavras; [3]Bolsista. Campus Universitário - Caixa Postal 3037 - CEP 37200-000 - Lavras - MG - Brasil. Universidade Federal de Lavras; [4]Bolsista. Campus Universitário - Caixa Postal 3037 - CEP 37200-000 - Lavras - MG - Brasil. Universidade Federal de Lavras; [5]Docente. Campus Universitário - Caixa Postal 3037 - CEP 37200-000 - Lavras - MG - Brasil. Universidade Federal de Lavras

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Quando se utiliza o penetrômetro para medir os valores de compressão, dependendo do nível de compactação no local onde é extraída a amostra, é necessário aplicar uma força maior para que o penetrômetro alcance a profundidade máxima de 60 cm, esta força gera um excesso de velocidade que pode afetar o resultado da resistência do solo a penetração pelo equipamento. O objetivo deste estudo foi avaliar se a ocorrência de excesso de velocidade aplicada a um penetrômetro pode afetar a coleta de dados do experimento em uma gleba, em uma área que passou pela operação de arranquio de cafeeiros. O experimento foi conduzido na Fazenda Santa Helena, localizada no município de Lavras, estado de Minas Gerais, Brasil, em uma área de 18 hectares destinadas ao cultivo de café. Os dados foram coletados por um penetrômetro digital em 48 pontos georreferenciados por um GNSS do tipo topográfico após o arranquio da lavoura cafeeira. As variáveis analisadas foram a ocorrência do excesso de velocidade, pressão máxima e a profundidade da pressão máxima, coletadas pelo penetrômetro. As análises de estatística descritiva e a regressão logística foram realizadas utilizando o software Rstudio e os resultados apontaram que os dados coletados em campo pelo penetrômetro não foram afetados pela ocorrência de excesso de velocidade do penetrômetro. Ressalta-se que o uso da técnica de Regressão Logística pode ser uma ferramenta importante para análises de compactação do solo e no auxílio de manejo da cultura do café.

PALAVRAS-CHAVE: Mecanização agrícola; resistência do solo a penetração; inteligência artificial

ABSTRACT

When using the penetrometer to measure compression values, depending on the level of compaction in the location where the sample is extracted, it is necessary to apply a greater force for the penetrometer to reach the maximum depth of 60 cm, this force generates excess speed. which can affect the result of soil resistance to penetration by the equipment. The objective of this study was to evaluate whether the occurrence of excessive speed applied to a penetrometer could affect the data collection of the experiment on a plot of land, in an area that underwent a coffee tree uprooting operation. The experiment was conducted at Fazenda Santa Helena, located in the municipality of Lavras, state of Minas Gerais, Brazil, in an area of ??18 hectares destined for coffee cultivation. The data was collected by a digital penetrometer at 48 points georeferenced by a topographic GNSS after the coffee crop was started. The variables analyzed were the occurrence of excess speed, maximum pressure and the depth of maximum pressure, collected by the penetrometer. Descriptive statistics analyzes and logistic regression were carried out using the Rstudio software and the results showed that the data collected in the field by the penetrometer were not affected by the occurrence of excessive speed of the penetrometer. It is noteworthy that the use of the Logistic Regression technique can be an important tool for analyzing soil compaction and helping to manage coffee crops.

KEYWORDS: ;;

INTRODUÇÃO

A compactação tem sido amplamente estudada no contexto da Agricultura de Precisão e o indicador mais utilizado para sua medição é a resistência do solo à penetração (SPR) empregando penetrômetro (**MOLIN et al., 2015**). A precisão da medição está altamente relacionada à capacidade de empurrar a sonda do penetrômetro na camada de solo pesquisada a uma velocidade constante, mesmo que seja quase impossível (CARRARA et al., 2007). Alguns aspectos podem interferir na medida da compactação, como a presença de humidade, textura e estrutura do solo (PIAS et al., 2018).

A avaliação e a sondagem do solo na averiguação do seu estado de compactação são procedimentos necessários para a análise da sua qualidade física (LIMA et al., 2013). A compactação é uma das principais causas da degradação física do solo e do crescimento atrofiado das plantas. O processo é definido como uma compressão no volume de um solo não saturado instigada por causas de natureza antrópica que reduzem o espaço poroso pela expulsão de ar e, em alguns casos, de água (**HILLEL, 1982**).

A implementação de sistemas intensivos de produção agrícola tem levado à utilização de máquinas pesadas com alta capacidade de trabalho, as quais requerem forças de tração elevadas (Carrara et al., 2007). O tráfego contínuo de máquinas agrícolas, especialmente em condições de alta umidade do solo, pode levar à compactação excessiva na superfície e subsuperfície do solo, junto a falta de diversificação de espécies vegetais e, muitas vezes, a má cobertura do solo proporcionada pelos resíduos da cultura (**BARETA JUNIOR *et al*., 2022; LIMA; PETTER; LEANDRO, 2015**, e **SHAFFIH-HADADI et al., 2009**).

OBJETIVOS

O objetivo deste estudo foi avaliar e a ocorrência de excesso de velocidade aplicada a um penetrômetro pode afetar o resultado da resistência do solo a penetração registrado pelo equipamento em uma gleba após o arranquio de uma lavoura de café.

MATERIAL E MÉTODOS

O trabalho foi desenvolvido na Fazenda Santa Helena, situada no município de Lavras no estado de Minas Gerais entre os dias de 02 de junho a 10 de outubro de 2023. A altitude média da área corresponde a 930m, a declividade média do terreno é de 5%. Segundo a classificação estabelecida pelo método de Köppen o clima regional é o subtropical com inverno seco (Cwb).

A área experimental era composta por uma lavoura de cafeeiros (*Coffea Arábica L.*) da cultivar Topázio MG 1190, plantada no espaçamento 3,5m entre linhas x 0,70m entre plantas, abrangendo uma área de 18 hectares. Este talhão possuía 40 anos de cultivo de café, sendo 20 anos submetido à mecanização agrícola, sem uso de práticas de controle de tráfego de máquinas pesadas com rodados.

As coletas dos dados de resistência a penetração do solo foram obtidas por meio da utilização de um penetrômetro digital Falker modelo PLG1020 para aferição a 60 cm de profundidade em relação à superfície, em 48 pontos georreferenciados por um equipamento GNSS do tipo navegação, seguindo a malha amostral da FIGURA 1. Além disto, para cada coleta de dados de resistência a penetração foram obtidas subamostras dos solos para a criação de amostras compostas, que foram submetidas a análises de umidade dos solos no Laboratório de Análise de Solo da Universidade Federal de Lavras.

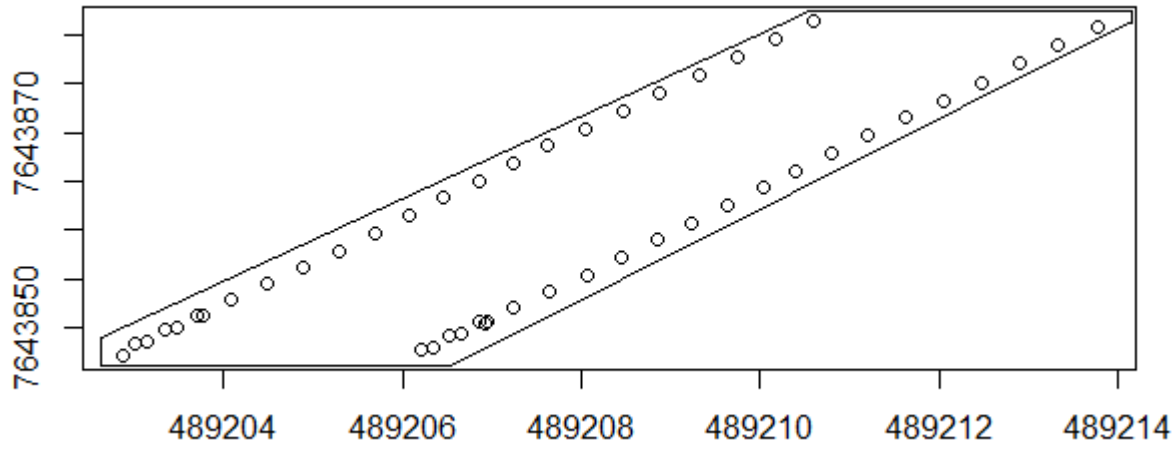


FIGURA 1. Pontos coletados na área de estudo.

A coleta dos dados foi realizada após o arranquio das plantas de cafeeiros existentes na área. Esta operação agrícola foi realizada por intermédio de um trator agrícola com rodado do tipo esteira metálica com peso 17627 kg, equipado com um implemento do tipo lâmina, para decepar e retirar o vestígio de plantação presente na parte visível do solo. À medida que o trator cumpria seu trabalho, pode-se inferir que houve um processo de modificação da estrutura do solo e até mesmo gerando compactação deste solo devido ao seu peso. Após este processo, realizou-se a coleta dos dados de resistência do solo a penetração (RSP) em pontos devidamente georreferenciados.

O penetrômetro, além de coletar os dados de pressão máxima, também coletou a ocorrência do excesso de velocidade, a medição completa, a profundidade máxima trabalhada na coleta de dados, o tipo de cone e a profundidade da pressão máxima. Dentre estes dados coletados pelo penetrômetro, foram selecionados os dados de pressão máxima, a ocorrência de excesso de velocidade e a profundidade máxima. Os dados foram analisados pelo Método de Regressão Logística para realizar uma previsão, se a ocorrência de excesso de velocidade interferiu ou não na coleta dos dados em campo.

A Regressão Logística foi utilizada para produzir, a partir de um conjunto de observações, um modelo que permita a predição de valores tomados por uma variável categórica, frequentemente binária, a partir de uma série de variáveis explicativas contínuas e/ou binárias. Em sua fórmula a probabilidade de ocorrência de um evento pode ser estimada diretamente. No caso da variável dependente Y assumir apenas dois possíveis estados (1 ou 0) e haver um conjunto de p variáveis independentes X1, X2, ..., Xp, o modelo de regressão logística pode ser escrito da seguinte forma:

$$P(Y=1)=\frac{1}{1+e^{-g(x)}}$$

onde,

$g(x)= B_0 + B_1X_1 + \cdots + B_pX_p$

No caso deste estudo, a variável dependente Y foi a ocorrência de excesso de velocidade do penetrômento e as variáveis independentes foram a pressão máxima e a profundidade da pressão máxima. Para a análise dos dados foi utilizado o software R Development Core Team, através da biblioteca geoR (Ribeiro Junior e Diggle, 2001).

RESULTADOS E DISCUSSÃO

Trabalhando com os dados aquisitados pelo penetrômetro digital, foram gerados resultados referentes à estatística descritiva, conforme a TABELA 1. A média aritmética demonstra o centro dos dados coletados. Já o desvio padrão apresentado demonstrou o quanto os dados estão dispersos em relação à média aritmética, ou seja, quanto mais distantes estão dos valores da média, maior a dispersão dos dados.

TABELA 1. Resultados da estatística descritiva dos dados coletados no arranquio do cafeeiro

	Média	Desvio Padrão
PM	3736,5	1357
PPM	25,7	15
OEV	0,875	0,334

Legenda: PM - Pressão Máxima (kPa); PPM - Profundidade da Pressão Máxima (cm); OEV - Ocorrência de excesso de velocidade.

Foi analisado a divisão dos dados para treinamento e teste sendo 80% dos dados foram destinados para treinamento e os outros 20% para teste. Baseado na estatística descritiva apresentada anteriormente, foi aplicada a técnica de Regressão Logística para observar o comportamento dos dados na obtenção de uma resposta categórica.

Na validação deste modelo, os dados foram submetidos a uma matriz de confusão a precisão deste modelo apresentou uma acurácia de 87,5%, com um intervalo de confiança de 95% para a estimativa de precisão, o coeficiente de Kappa de 0,85, indicando que não há concordância entre os resultados originais e os resultados previstos. O p-valor foide 0,7450, sendo considerado estatisticamente não significativo, com uma especificidade de 0, o que significa que o modelo não identificou casos negativos.

Neste caso, o excesso de velocidade não afetou a coleta dos dados em campo, não havendo efeitos significantes que pudessem comprovar que o excesso de velocidade do penetrômetro pudesse comprometer as amostras. O uso do penetrômetro em um solo compactado por passagens de máquinas agrícolas são de extrema importância, pois a presença de pedras, o efeito da profundidade e a variabilidade dos valores podem interferir na medida e interpretação dos valores medidos Campbell e O'Sullivan (1991).

A principal diferença está relacionada à velocidade de inserção da haste no solo, que pode ser constante ou interferir nos resultados das medições *in situ*, segundo o operador (Herrick & Jones, 2002). A confiabilidade dos dados gerados pelos penetrômetros manuais está diretamente relacionada ao controle da velocidade da haste durante a inserção no solo, embora manter uma velocidade constante seja quase impossível (Carrara et al., 2007). Assim, quando a velocidade não é constante, a força aplicada também não o é (Herrick & Jones, 2002); se a velocidade de inserção da haste for acelerada, a força aumenta e diminui no caso de desaceleração (Sol et al., 2006).

CONCLUSÃO

Os resultados deste trabalho não detectaram efeitos significantes que pudessem comprovar o comprometimento das amostras coletadas por intermédio da ocorrência de excesso da velocidade aferida pelo penetrômetro.

Os dados de compactação do solo causado pelas diversas passadas de máquinas agrícolas não foram afetados, trazendo a tona a importância do uso de análises estatísticas e do método de Regressão Logística no auxilio da tomada de decisão em sistemas de gestão e manejo do solo.

AGRADECIMENTOS

UFLA/PPGEA, CNPq (projeto 310186/2023-4), FAPEMIG (projeto APQ-00661-22), EMBRAPA Café - Consorcio pesquisa café (projeto 10.18.20.041.00.00), CAPES.

REFERÊNCIAS

BARETA JUNIOR, E. *et al.* Critical limits of soil physical attributes for corn and black oat in a Xanthic Hapludox. **Revista Ciência Agronômica**, v. 53, e20207533, 2022.

CAMPBELL, D. J.; O'SULLIVAN, M. F. The cone penetrometer in relation to, trafficability, compaction and tillage. In: SMITH, K. A.; MULLINS, C. E. (Ed.). **Soil analysis.** New York: M. Dekker, 1991. p. 399-423.

CARRARA, M.; CASTRIGNANÒ, A.; COMPARETTI, A.; FEBO, P. & ORLANDO, S. Mapeamento da resistência do penetrômetro em relação ao tráfego de tratores utilizando geoestatística multivariada. **Geoderma**, 142:294-307, 2007.

HERRICK, JE & JONES, TL A dynamic cone penetrometer for measuring soil penetration resistance. **Ciência do Solo**. Soc. Sou. J., 66:1320-4, 2002.

HILLEL, D. Introduction to soil physics. New York: **Academic Press**; 1982.
LIMA, L. B.; PETTER, F. A.; LEANDRO, W. M. Desempenho de plantas de cobertura sob níveis de compactação em Latossolo Vermelho de Cerrado. **Revista Brasileira de Engenharia Agrícola e Ambiental,** v. 19, n. 11, p. 1064-1071, 2015.

LIMA, R. P. de; DE LEÓN, M. J.; SILVA, A. R. da. Comparação entre dois penetrômetros na avaliação da resistência mecânica do solo à penetração. **Revista Ceres**, Viçosa, v. 60, n.4, p. 327 577-581, 2013.

MOLIN, J. P. et al. **Agricultura de Precisão.** 1.ed. São Paulo: Oficina de Textos, 2015. 224p.

PIAS, O. H. de C., Cherubin, M. R., Basso, C. J., Santi, A. L., Molin, J. P., & Bayer, C.. (2018). Soil penetration resistance mapping quality: effect of the number of subsamples. Acta Scientiarum. Agronomy, 40, e34989. https://doi.org/10.4025/actasciagron.v40i1.34989

RIBEIRO JUNIOR, P.J., DIGGLE, P.J. Junho 2001. GeoR: a package for geostatistical analysis. **R-New**, Nova York, 1(2), pp.

SAFFIH-HDADI, K; DÉFOSSEZ, P.; RICHARD, G., CUIi ,Y.J.; TANG, A.M, CAPELÃO, V. A method for predicting soil susceptibility to compaction of surface layers as a function of water content and bulk density.

Solo até Res. 2009;105:96-103.

SOL., Y.; LIN, J.; LOUCO.; ZENG, Q. & SCHULZE, PL. Penetration force measurement using a Hall current sensor. **Solo até. Res**., 92:264-268, 2006.

RELAÇÃO DE ÍNDICES ESPECTRAIS DE VEGETAÇÃO COM ATRIBUTOS EDÁFICOS EM ÁREA DE PASTAGEM COM MANEJO ROTACIONADO

JOAO RICARDO FAVAN [1]; RENATA BRUNA DOS SANTOS COSCOLIN FAVAN [1]; JOAO VITOR IENCO BONACINA [2]; JOAO PEDRO IENCO BONACINA [2]; LUIS HENRIQUE SERAFIM DA SILVA [2]

[1]Docente. Avenida Fundação Shunji Nishimura, 605 - Jardim São Luiz CEP 17586-050 - Pompeia/SP. Faculdade de Tecnologia Pompeia - Shunji Nishimura; [2]Discente. Avenida Fundação Shunji Nishimura, 605 - Jardim São Luiz CEP 17586-050 - Pompeia/SP. Faculdade de Tecnologia Pompeia - Shunji Nishimura

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A pecuária extensiva em pastagens degradadas é um desafio para pequenos produtores. A agricultura de precisão, com o uso do índice GCI, pode auxiliar no monitoramento da saúde da vegetação e dos atributos edáficos, possibilitando a otimização do manejo e a recuperação das pastagens. O conhecimento espacial dos atributos do solo e sua relação com a vegetação em pastagens, obtido por ferramentas de sensoriamento remoto, é crucial para o manejo eficiente das pastagens. Este estudo mapeou a variabilidade espacial do GCI e sua correlação com atributos químicos do solo em pastagem de capim braquiária sob manejo rotacionado em Pirajuí (SP). O estudo foi realizado em três piquetes de uma pastagem. Imagens de sensoriamento remoto do Sentinel-2 foram utilizadas para calcular o GCI. Amostras de solo foram coletadas e analisadas para determinar teores de nutrientes, pH e V%. A correlação de Pearson foi utilizada para avaliar a relação entre GCI e as propriedades do solo. Os resultados mostraram que o índice GCI apresentou um perfil similar entre os piquetes ao longo do ano, com maiores valores no período das águas e menores no período de seca. A análise estatística demonstrou diferenças significativas entre os piquetes para os atributos P, Mg, pH, MO e V%. Esses atributos foram interpolados com o método IDW e seu resultado utilizado na correlação com o índice de GCI. As correlações entre os atributos foram medianas e altas, no entanto, as correlações entre GCI e os atributos de solo foram baixas. O índice GCI, embora não apresente correlação direta com todos os nutrientes do solo, demonstrou utilidade no direcionamento da coleta de solo para análise e na identificação de áreas de pastagem degradadas, ao se associar ao comportamento de atributos chaves, como o pH e V%. Com isso, o índice serviu como ferramenta simplificada para o manejo da rotação de pastagem, quando associado aos atributos edáficos da área de estudo.

PALAVRAS-CHAVE: Índice de clorofila verde; pastejo rotacionado; nutrientes do solo

ABSTRACT

Extensive livestock farming in degraded pastures is a challenge for small farmers. Precision agriculture, using the GCI index, can assist in monitoring vegetation health and soil attributes, enabling the optimization of management and the recovery of pastures. Spatial knowledge of soil attributes and their relationship with vegetation in pastures, obtained by remote sensing tools, is crucial for efficient pasture management. This study mapped the spatial variability of GCI and its correlation with soil chemical attributes in a brachiaria grass pasture under rotational grazing in Pirajuí (SP), Brazil. The study was conducted in three paddocks of a pasture. Sentinel-2 remote sensing images were used to calculate the GCI. Soil samples were collected and analyzed to determine nutrient contents, pH, and V%. Pearson correlation was used to assess the relationship between GCI and soil properties. The results showed that the GCI index presented a similar profile between the paddocks throughout the year, with higher values in the rainy season and lower values in the dry season. The statistical analysis showed significant differences between the paddocks for the attributes P, Mg, pH, MO, and V%. These attributes were interpolated with the IDW method, and their result was used in the correlation with the GCI index. The correlations between the attributes were median

and high, however, the correlations between GCI and soil attributes were low. The GCI index, although it does not directly correlate with all soil nutrients, showed utility in directing soil collection for analysis and in identifying degraded pasture areas, when associated with the behavior of key attributes, such as pH and V%. With this, the index served as a simplified tool for managing pasture rotation, when associated with the soil attributes of the study area.

KEYWORDS: sensoriamento remoto; monitoramento

INTRODUÇÃO

A atividade pecuária exercida por pequenos produtores, com foco na atividade em sistema extensivo, enfrenta desafios significativos devido à degradação das pastagens. As principais causas dessa degradação incluem superlotação das áreas, declínio da fertilidade do solo pela falta de adubação e manejo inadequado das pastagens (Dias-Filho, 2017).

A degradação das pastagens é caracterizada pelo gradual declínio do vigor, produtividade e valor nutricional das forrageiras, comprometendo a capacidade da espécie de sustentar a produção animal e a resistência e/ou tolerância a pragas, doenças e plantas invasoras (Dias-Filho, 2017).

A agricultura de precisão (AP) tem sido uma ferramenta útil para os produtores na gestão dos diferentes sistemas de cultivo, no entanto, sua eficácia depende da capacidade de avaliar a variabilidade espacial do solo e das culturas de maneira eficiente e econômica. Essa prática tem impulsionado o desenvolvimento de sistemas de sensoriamento e monitoramento para identificar os fatores limitantes à produção em áreas específicas (Bernardi, 2014).

O potencial da AP em sistemas de produção animal, especialmente aqueles baseados em pastagens, tem sido destacado na literatura. As características do sensoriamento remoto, como a cobertura espectral, a revisita periódica e a capacidade de cobrir grandes áreas, tornam-na uma ferramenta promissora para o monitoramento das pastagens à medida que diminui a mistura dos dados espectrais com outros alvos ou feições terrestres (Bernardi; Perez, 2014).

Dentre os índices de vegetação (IVs) abordados em literatura, para o presente estudo foi selecionado o Green Chlorophyll Index (GCI). Este índice, assim como o NDVI e EVI, são ferramentas valiosas para o monitoramento ambiental, fornecendo medições quantitativas e qualitativas do vigor da vegetação em uma área específica (Bannari et al., 1995; Shiratsuchi et al., 2014).

Através da análise da reflectância espectral da vegetação, os IVs permitem detectar alterações no uso do solo, estimar diversos aspectos da cobertura vegetal, como vigor, saúde, biomassa, teor de clorofila, entre outros parâmetros, possibilitando, em alguns casos, identificar o tipo de cultura e estimar a possível produtividade da área (Vilamuelas et al. 2016).

O GCI é especialmente útil para estimar o teor de clorofila em áreas de alta densidade foliar, o que pode fornecer informações importantes sobre a saúde e o estado fisiológico das plantas. A partir da análise do GCI, os pesquisadores podem inferir, além da produtividade das plantas, a qualidade da vegetação e até mesmo detectar estresses ambientais precocemente detectado pela redução desse índice (Kumar, et al 2018).

Estudos demonstram que o GCI apresenta uma relação significativa com alguns atributos edáficos, como a matéria orgânica (MO), uma vez que a maior teor de matéria orgânica está associado a um aumento no GCI, indicando teores elevados de clorofila e biomassa vegetal (Sims & Gamon, 2002; Zhang et al., 2008).

O Nitrogênio é o elemento mais abundante em áreas com elevado teor de matéria orgânica (MO). Ele é essencial para o crescimento e desenvolvimento das plantas, e sua disponibilidade no solo pode influenciar o índice GCI (Sims & Gamon, 2002).

Dessa maneira, o GCI é um índice promissor para o monitoramento da saúde da vegetação e de atributos edáficos (D'Oliveira, 2014). Com isso, a combinação entre o GCI com outros IVs aliados a dados edáficos adquiridos através de análise de solo pode fornecer informações valiosas para melhorias no sistema de manejo rotacionado e manutenção de áreas de pastagem evitando assim a degradação. Neste contexto, o conhecimento da distribuição espacial dos atributos do solo e sua relação com a vegetação das pastagens por meio de ferramentas de AP pode ser crucial para o manejo eficiente das pastagens.

OBJETIVOS

O objetivo deste estudo foi mapear a variabilidade espacial do índice de clorofila verde (GCI) e potencial correlação entre os atributos químicos do solo em uma pastagem de capim braquiária sob manejo rotacionado em Pirajuí (SP).

MATERIAL E MÉTODOS

Caracterização da área

O ensaio foi realizado na propriedade Fazenda Vale Verde, no município de Pirajuí- SP, em uma área de aproximadamente 472 ha. A área de pastagem com cultivo de capim brachiaria spp. foi utilizada para recria de gado nelore (Bos taurus) em sistema de manejo rotacionado. A propriedade foi dividida em 13 piquetes, sendo selecionados para o estudo 3 deles, de acordo com a sequência de uso: Piquete 1 (posterior o uso), Piquete 2 (em uso) e Piquete 3 (próximo a ser usado), durante o período experimental, compreendido entre 05 de janeiro a 15 de fevereiro de 2024.

Aquisição e processamento dos dados de sensoriamento remoto

Imagens de sensoriamento remoto foram adquiridas da área de estudo entre 01 de janeiro de 2023 e 31 de dezembro de 2023. As imagens foram obtidas pelo satélite Sentinel-2 (SENTINEL, 2014), com um critério de seleção que incluiu apenas aquelas com menos de 20% de cobertura de nuvens. Posteriormente, um processo de filtragem foi aplicado para eliminar pixels com presença de nuvens ou cirros, resultando em um mosaico de imagens adequadas para análise (COLUZZI et al., 2018).

Cálculo do Índice de Clorofila Verde (GCI)

O GCI foi calculado a partir das imagens processadas utilizando a função padrão para essa finalidade, com base na equação apresentada na Fórmula 1. O valor do GCI foi incorporado como uma banda em cada imagem processada (AMIRI & POURGHASEMI, 2022).

$$GCI = \frac{NIR}{VERDE} - 1$$

(1)

Onde: GCI: índice de clorofila verde para um determinado pixel; NIR: valor da refletância do comprimento de onda do infravermelho próximo (842 µm) para um pixel; VERDE: valor da refletância do comprimento de onda verde visível (560 µm) para um pixel

Todo o processo de aquisição e processamento das imagens foi realizado utilizando a plataforma Google Earth Engine (GEE) (GORELICK et al., 2017), com um script desenvolvido em linguagem JavaScript.

Análise de solo

Os pontos georreferenciados de coleta de solo foram determinados a partir da análise da mediana do índice GCI, sendo posicionados, para cada piquete, 3 pontos em uma região de valores inferiores do índice (0.8 a 1.03), 3 pontos para valores intermediários (1.03 a 1.26) e 3 pontos para valores superiores do GCI (1.26 a 1.5), como apresentado pela Figura 1. O solo em cada um desses pontos foi amostrado a uma profundidade de 0 a 15 cm, e enviados para análise físico-química ao Laboratório de Solos da Fundação Shunji Nishimura de Tecnologia, localizado na cidade de Pompéia-SP.

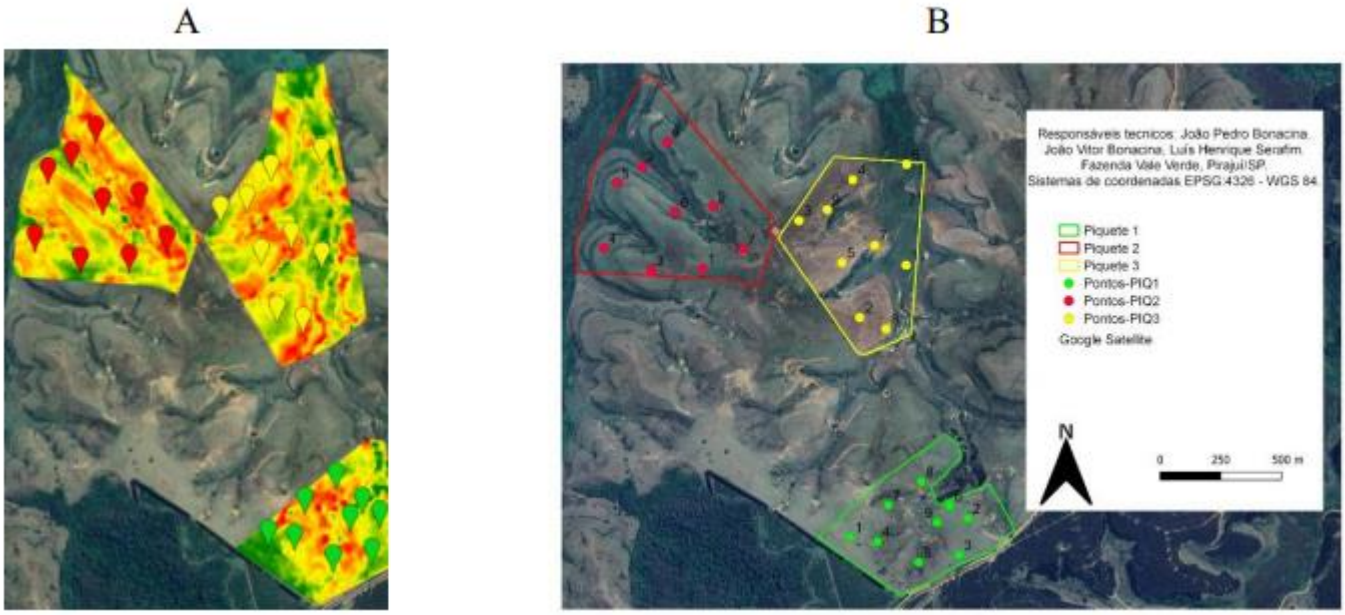


FIGURA 1. Mapa do Índice de Clorofila Verde (GCI) com pontos georreferenciados para amostragem de solo dos piquetes 1, 2 e 3 (A). Delimitação da área dos piquetes 1 (verde), 2 (vermelho) e 3 (amarelo) conjuntamente com os pontos georreferenciados para coleta de amostras de solo (B).

Análise estatística

Os dados de PH (PHCACL2 e PHH2O), fosforo (P), potássio (K), cálcio (Ca), magnésio (Mg), alumínio (Al), acidez potencial (H+AL), soma de bases (SB), capacidade de troca catiônica (CTC) e saturação por base (V) foram submetidos à análise de normalidade pelo método de Shapiro (Shapiro, 1965). Os atributos de MO, PCCACL2, PHH2O, MG e V foram analisadas pelo teste de comparação de médias entres os piquetes utilizando a análise de variância (ANOVA) e suas diferenças foram averiguadas pelo teste de Tukey. Os dados de P, K, CA, SB, CTC foram submetidas a outros testes estatístico, por não apresentarem distribuição normal de dados, no qual suas medianas foram avaliadas pelo teste de Kruskal-Wallis (KRUSKAL & WALLIS, 1952), e as diferenças entre os piquetes foi determinada pelo teste de Dunn (DINNO, 2015).

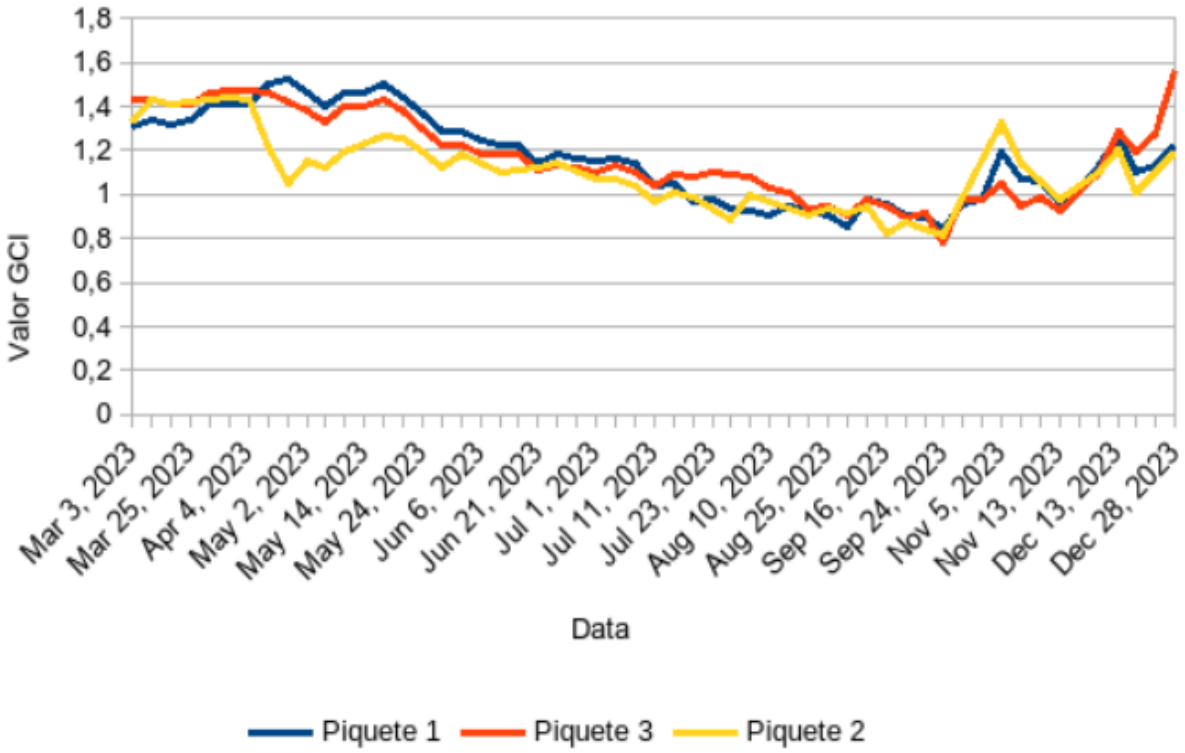
Interpolação dos dados

Os valores obtidos de P, V, MO, MG e PH foram interpolados, utilizando o algoritmo IDW (Burrough e McDonnell, 1998), para toda área de cada piquete, e foi analisado a correlação de Pearson (Pearson, 1996) entre essas imagens interpoladas e o índice de vegetação GCI com finalidade de avaliar o

comportamento do índice em relação aos teores de nutrientes, pH e V% contidos no solo. Assim como, foi realizado a análise de variância e teste de médias de Tukey dos valores interpolados dessas variaveis para cada piquete, utilizando o software estatístico Jamovi versão 2.5 (JAMOVI, 2024).

RESULTADOS E DISCUSSÃO

Durante todo o ano de 2023 os 3 piquetes analisados apresentaram um perfil semelhante de comportamento do índice de GCI, sugerindo uma uniformidade entre essas áreas, de tal forma que, para este indicador, não foi percebida nenhuma alteração significativa da rotação da pastagem ao longo do ano, como mostrado na Figura 2.



Perfil do índice GCI mediano ao longo do ano de 2023 para os 3 piquetes estudados

FIGURA 2. Perfil de comportamento da mediana do índice de clorofila verde (GCI) para os 3 piquetes estudados ao longo do ano de 2023

O valor mediano do índice GCI durante o ano de 2023 variou entre 0.77 e 1.52, sendo o Piquete 1 alcançou seu menor valor de 0.9 em setembro e seu maior valor de 1.52 no mês de maio, por sua vez o piquete 3 obteve os valores de 0.79 em outubro e 1.48 em abril, respectivamente, e, finalmente, o piquete 2 obteve os valores de 0.82 em setembro e 1.44 em abril. Dessa forma pode ser percebido que os maiores valores de GCI estão concentrados na porção central do primeiro semestre (período das águas), enquanto os menores valores estão concentrados no segundo semestre (período de seca), entre os meses de setembro e outubro.

Os índices de vegetação, de forma mais generalizada, são considerados ferramentas interessantes para monitoramento da saúde das culturas, considerando índices como o GCI, NDVI e EVI que são ligados à quantidade de clorofila das plantas (Tong; He, 2014). Esses índices são largamente utilizados e demonstram a condição geral do campo, embora sua relação com determinados nutrientes do solo carece de maiores estudos (Bascietto; Santangelo; Beni, 2021).

A análise do teor de nutrientes para cada piquete mostrou que há uma diferenciação entre os piquetes amostrados, de tal forma que o piquete 3 se destaca quantitativamente, com valores superiores, em

todos os atributos de solo analisados, como mostra a Tabela 1. Dessa forma, percebe-se que o Piquete 3 apresenta valores maiores para todos os nutrientes uma vez que se trata de um piquete que entrará em uso no sistema de rotação adotado, dessa forma, houve tempo para reestabelecimento dessa melhor condição (Pissinati; Moreira; Santoro, 2018).

TABELA 1. Médias (desvio padrão entre parênteses) para os atributos de solo dos piquetes 1 (posterior ao uso), 2 (em uso) e 3 (anterior ao uso).

	Piquete 1		**Piquete 2**		**Piquete 3**		
MO (g/dm^3)	8,55 (2,5)		9,44 (3,0)		11,33 (3,0)		**
pHCACl$_2$	4,42 (0,15)	b	4,56 (0,2)	b	4,95 (0,14)	a	**
pHH$_2$O	5,22 (0,15)	b	5,35 (0,18)	b	5,67 (0,10)	a	**
P (mg/dm^3)	3,0 (1,0)	b	3,0 (0,72)	b	6,0 (2,08)	a	*
K (mmolc/dm^3)	1,7 (0,46)		2,9 (1,7)		2,5 (0,99)		*
Ca (mmolc/dm^3)	13 (8,9)		17 (10,11)		19 (14,76)		*
Mg (mmolc/dm^3)	6,23 (2,55)	b	6,56 (3,09)	b	11,3 (3,97)	a	**
SB (mmolc/dm^3)	21 (11,27)		27 (14,56)		32 (18,86)		*
CTC (mmolc/dm^3)	53 (15,92)		52 (14,31)		48 (19,56)		*
V% (%)	55,44 (15,92)	b	54,66 (14,31)	b	57,88 (19,56)	a	**

** Letras minúsculas na mesma linha apresentam a diferenciação entre os piquetes para um determinado atributo submetido ao teste de tukey com 95% de probabilidade

* Letras minúsculas na mesma linha apresentam a diferenciação entre os piquetes para um determinado atributo submetido ao teste de dunn com 95% de probabilidade

Atributos de Solo

Os valores de pH do solo nos piquetes 1, 2 e 3 foram 5,22, 5,35 e 5,67, respectivamente (Figura 1). Os piquetes 1 e 2 apresentaram os menores valores de pH, sem diferença estatística entre si ($p > 0,05$). O piquete 3 apresentou o maior valor de pH, diferindo estatisticamente dos piquetes 1 e 2 ($p < 0,05$). De acordo com Alvarez et a. (1999), os valores encontrados para o pH são considerados bons para áreas de pastagem de acordo com sua classificação, entretanto o estudo corrobora com o autor uma vez que uso do solo sob pastagem reduzem os valores de pH do solo. Isso é observado à medida que na data de coleta de solo foram selecionados os piquetes de acordo com a ordem de pastejo, piquete 1- posterior ao uso, piquete 2- em uso e piquete 3 - próximo ao uso.

Os menores valores de pH nas áreas de pastagem estão associados à maior exposição ao solo, por consequência menor intensidade de área foliar associada ao menor índice de clorofila verde. Dessa maneira, esse índice poderá ser indicado para direcionar a ordem entre os piquetes para ser utilizado.

Estudos demonstram que a acidez do solo pode afetar negativamente a produtividade de espécies forrageiras, reduzindo a absorção de nutrientes pelas plantas, assim como, seu potencial produtivo (Veiga et al., 2015). A longo prazo, essa acidez do solo pode levar à maior porcentagem de solo

exposto, perda da matéria orgânica, capacidade de retenção de água acarretando na degradação do solo, influenciando assim diretamente na qualidade química do solo (Fageria & Baligar, (2008) Bayer et al., 2013).

Em solos ácidos, a maior concentração de Al+3, principalmente na forma de íons livres, leva à formação de complexos insolúveis com o P. Essa complexação torna o P indisponível para as plantas, limitando seu crescimento e desenvolvimento (Novais et al. 2007), dessa forma, os valores de P mais baixos encontrados nos piquetes 1 e 2 podem estar associados aos baixos pH encontrados nos mesmos piquetes os quais para o atributo de P também diferem do piquete 3.

De acordo com a intensificação do uso das pastagens observam-se maiores teores de Al+3 (acidez trocável) e H+Al (acidez potencial) de acordo com a Tabela 2

TABELA 2. Médias para os atributos de acidez potencial e acidez trocável para o solo dos piquetes 1 (posterior ao uso), 2 (em uso) e 3 (anterior ao uso).

Atributo	Piquete 1	Piquete 2	Piquete 3
Al^{+3}	2,78	2,89	1,33
H+Al	12,1	13,4	8,44

A baixa disponibilidade de P em áreas de pastagem com manejo rotacionado pode ser um problema significativo para a produtividade das pastagens. O manejo adequado da pastagem, com foco na correção do pH do solo e na adubação fosfatada, é essencial para aumentar a disponibilidade de P e garantir a produtividade das pastagens.

Comportamento semelhante ao pH foi observado com o elemento Mg entre os piquetes. Piquetes 1 e 2 não diferem entre si, entretanto diferem do piquete 3 o qual apresenta valores superiores de Mg. Resultados semelhantes foram encontrados por Favero et al (2008), onde em solo sob sistema agroflorestal apresentou teores mais elevados do elemento quando comparado a um sistema de pastagem.

Estudo realizados por Souza et al. (2001) e Oliveira et al. (2003) envolvendo recuperação de áreas de pastagem degradadas demonstraram a importância de manter os teores de Ca+2 e Mg+2 em níveis adequados uma vez que a ação desses nutrientes proporciona maior produção de matéria seca na pastagem, pois reduzem a saturação do alumínio e o aumento da disponibilidade de nutrientes como N, P e K que são essenciais ao desenvolvimento da gramínea.

O P atua no armazenamento e na transferência da energia para transporte eletrônico durante o processo de fotossíntese, enquanto o Mg, além de fazer parte da estrutura da molécula da clorofila, é também cofator da hidrólise do ATP, (Marschner, 1995; Malavolta et al., 1997, Taiz; Zeiger, 2007).

O manejo rotacionado age na preservação e distribuição dos nutrientes do solo para a planta dessa forma a planta realiza ações metabólicas para produção de biomassa, ou de hibernar de forma a preservar o estado nutricional interno para sobreviver a agentes estressores (Tagliapietra et al. 2021), outro ponto que corrobora nesse estudo para o uso do índice GCI como fator de direcionamento da malha amostral destinada a análise de solo da área e/ou identificação de qual piquete será manejado.

A saturação por bases elevada indica maior disponibilidade de nutrientes essenciais para as plantas, como nitrogênio, fósforo e potássio, o que promove o crescimento e a produtividade das pastagens. Esse atributo é fortemente correlacionado de acordo com a Tabela 3 com os atributos de pH, M.O e CTC os quais quando apresentam altos valores favorecem o desenvolvimento de raízes das plantas.

Dessa forma, o índice GCI uma vez que se relaciona com o desenvolvimento vegetativo da forrageira pode-se observar que os atributos químicos como o P , Mg e M.O também diferiram entre os piquetes, sendo fatores essenciais para o processo fotossintético, entretanto as correlações entre os valores interpolados desses atributos com o índice não são fortes.

Interpolação dos dados de nutriente e correlação com o índice GCI

O processo de interpolação dos dados permitiu aumentar a quantidade de dados e a variabilidade deles para cada atributo, dessa forma, a análise que inicialmente foi feita com 27 pontos de dados, passou a contar com 1569 pontos de dados, abrangendo toda a área de estudo, aqui caracterizada pelos 3 piquetes.

Os dados interpolados mostraram correlações medianas e altas (de 0.47 a 0.93) entre os nutrientes com destaque para as correlações entre soma de base (V) e pH (PH), na casa dos 0.906 e magnésio (MG) com pontuação de 0.933. A elevada correlação entre esses nutrientes já foi relatada em diversos trabalhos como Moritsuka et. al (2011), Liu et. al (2016) e Komolafe et. al (2021), que trabalharam essa correlação com dados coletados, destaca-se, para o presente trabalho, o comportamento semelhante para os dados interpolados, como mostrado na Tabela 3

TABELA 3. Coeficiente de correlação de pearson para os dados interpolados dos atributos de solo pH (PH), magnesio (MG), materia orgânica (MO), fosforo (P), soma de base (V) e o Índice de clorofila verde (GCI)

	V% (%)	pH	Mg (mmolc/dm^3)	MO (g/dm^3)	P (mg/dm^3)
pH	0,906				
Mg (mmolc/dm^3)	0,933	0,839			
MO (g/dm^3)	0,362	0,495	0,476		
P (mg/dm^3)	0,667	0,797	0,685	0,576	
GCI	-0,117	-0,086	-0,060	0,000	-0,129

Por outro lado, quando tratado da correlação entre o índice de vegetação GCI e os demais atributos de solo, foi percebido valores muito baixos para essas relações, na ordem entre 0.000 e 0.129, tanto para correlações diretas como inversas, indicando que este índice não apresenta comportamento semelhante ao de nenhum dos atributos analisados, não permitindo estabelecer nenhuma relação de predição desse índice e os atributos de solo. Diversos trabalhos apontam que índices de vegetação como o NDVI e EVI podem apresentar alguma correlação com nutrientes em culturas como morango, milho, arroz, tomate, entre outras (Li et. al, 2010; Agrahari et. al, 2021), no entanto, esse comportamento não foi relatado no presente trabalho.

A estimação de teores e concentrações de nutrientes de solos, como Ca, K, Mg, N, P, Mn e Fe por meio de ferramentas de sensoriamento remoto estão associados ao uso de dados provenientes de espectroscopia, principalmente na banda do infravermelho médio e distante (Manley, 2014; Erler, et. al, 2020), sendo essas regiões não utilizadas para a formação do índice GCI utilizado no presente trabalho.

Embora esse índice não tenha se mostrado adequado para correlacionar-se com os nutrientes de solo, ele se mostrou adequado para acompanhamento da saúde da cultura, como mostrado nos trabalhos de Kahsay (2022) e Tayade (2022), da mesma forma, esse indicador, foi capaz de diferenciar-se entre os piquetes estudados, mostrando sua possibilidade de uso, na avaliação da qualidade do produto

vegetativo de um talhão. Dessa forma pode ser observado a diferenciação do índice de GCI entre os piquetes estudados, como mostra a Tabela 4

Tabela 4 - Medianas (desvio padrão entre parênteses) para os atributos de solo interpolados e índice de clorofila verde (GCI) dos piquetes 1 (posterior ao uso), 2 (em uso) e 3 (anterior ao uso).

Atributo	Piquete 1	Piquete 2	Piquete 3
GCI	1,15 (0,16) a	1,12 (0,13) b	1,17 (0,15) a
P (mg/dm^3)	3,58 (0,5) b	3,25 (0,53) c	6,27(1,25) a
MO (g/dm^3)	9,03 (1,88) c	9,35 (1,89) b	11,1 (2,19) a
Mg (mmolc/dm^3)	6,60 (1,38) b	6,60 (2,22) c	11,0 (2,68) s
pH	5,20 (0,08) c	5,35 (0,14) b	5,66 (0,08) a
V% (%)	45,1 (5,52) b	49,7 (9,63) c	65,5 (7,30) a

Letras minúsculas na mesma linha apresentam a diferenciação entre os piquetes para um determinado atributo submetido ao teste de comparações múltiplas de Dwass-Steel-Crichlow-Fligner com 95% de probabilidade

O teste de diferenciação de medianas, apresentou que para os dados interpolados de todos os atributos de solo, há uma diferenciação entre os piquetes, mostrando assim, que todos os piquetes revelam índices diferenciados desses nutrientes seja este piquete em uso (piquete 2), após o uso (piquete 1) ou pronto para uso (piquete 3). Por outro lado, para o indicador GCI, há uma diferenciação entre o piquete que está em uso (piquete 2) dos demais piquetes, essa diferenciação pode ser causada pelo consumo da pastagem no piquete em uso (menor área fotossintética disponível) e maior exposição do solo (Hott et. al, 2021).

O Índice de Vegetação GCI (Green Chlorophyll Index) é um indicador da saúde das plantas e da produtividade da pastagem, estimado através de sensores remotos. Esse índice é altamente correlacionado com a quantidade de clorofila presente nas plantas, sendo um indicador direto da atividade fotossintética e, consequentemente, da produtividade vegetal.

A indicação do o GCI associado ao atributo V% demonstram a importância de manter a fertilidade do solo para garantir a produtividade da pastagem. Práticas de manejo que contribuem para a saturação por bases e fertilidade do solo, como a calagem, adubação e a melhor seleção dos piquetes durante o manejo rotacionado, podem aumentar o GCI e, consequentemente, a produtividade da pastagem.

O monitoramento da área através do índice do GCI para direcionamento amostral para análise de fertilidade do solo pode ser ferramenta útil para o manejo da pastagem, permitindo direcionar os piquetes para rotação.

CONCLUSÃO

O índice de vegetação GCI, embora não apresente uma forte correlação entre os nutrientes do solo para direcionamento do manejo da pastagem, esse mesmo índice apresentou a capacidade de diferenciar as áreas de estudo entre aquelas que estão em uso daquelas que não estão em uso, quando associados aos atributos nutricionais sinalizados no presente trabalho, devido a sua variabilidade

espacial, dessa forma este indicador pode ser utilizado para manejo das áreas de pastagem, como uma metodologia simplificada para definição do manejo da rotação de pastagem.

REFERÊNCIAS

AGRAHARI, R.K.; KOBAYASHI, Y.; TANAKA, T.S.T.; PANDA, S.K.; KOYAMA, H. Smart fertilizer management: the progress of imaging technologies and possible implementation of plant biomarkers in agriculture. **Soil Science and Plant Nutrition**, v. 67, n. 3, 2021. p. 248-258. doi: https://doi.org/10.1080/00380768.2021.1897479. Acesso em 03 abr. 2024.

ALVAREZ, V. H.; NÓBREGA, J. C. A. **Classificação de solos**. Embrapa Solos. 1999.

BASCIETTO, M.; SANTANGELO, E.; BENI, C. Spatial Variations of Vegetation Index from Remote Sensing Linked to Soil Colloidal Status. **Land**. n. 10, v. 80, 2021, doi: https://doi.org/10.3390/land10010080

BAYER, C.; OLIVEIRA, P. T. S.; MENDONÇA, M. S. Soil organic matter under different grazing intensities in a tropical rangeland. **Soil Science Society of America Journal**, v. 77, n. 5, 2013. p. 1639-1649.

BURROUGH, P.A., MCDONNELL, R.A. Creating continuous surfaces from point data. In: BURROUGH, P.A., GOODCHILD, M.F., MCDONNELL, R.A., SWITZER, P., WORBOYS, M. (Eds.), **Principles of Geographic Information Systems**. Oxford University Press, Oxford, UK. 1998.

D'OLIVEIRA, P.S.; HOTT, M.C.; ANDRADE, R.G.; MAGALHÃES, W.C.P. **Aplicações da agricultura de precisão em pastagens**. Embrapa, 2014. 32 p. Disponível em: https://ainfo.cnptia.embrapa.br/digital/bitstream/doc/1151612/1/Aplicacoes-da-agricultura-de-precisao-em-pastagens.pdf. Acesso em: 03 abr 2024.

ERLER, A.D.; RIEBE, T.; BEITZ, H.G.; LÖHMANNSRÖBEN, D.; GEBBERS, R. Soil Nutrient Detection for Precision Agriculture Using Handheld Laser-induced Breakdown Spectroscopy (LIBS) and Multivariate Regression Methods (PLSR, Lasso and GPR). **Sensors**, v. 20, n. 2, 2020. p. 418. doi:10.3390/s20020418. Acesso em 03 abr. 2024.

FAGERIA, N. K.; BALIGAR, V. C. Ameliorating soil acidity of tropical soils with lime and other amendments. **Journal of Plant Nutrition**, v. 31, n. 11, 2008. p. 2000-2031.

HOTT, M.C. et al. Classification of Cynodon spp. grass cultivars by UAV, **International Journal of Advanced Engineering Research and Science**, v. 8, n. 12, 2021. p. 266-270. doi:10.22161/ijaers.812.26. Acesso em 02 abr. 2024

KAHSAY, A.G. Comparison of thermal infrared and multispectral UAV imagery for detecting pine trees (Pinus Brutia) health status in Lefka Ori National Park in West Crete, Greece. 2022.

KOMOLAFE, A.A.; OLORUNFEMI, I.E.; OLORUNTOBA, C.; AKINLUYI, F.O. Spatial prediction of soil nutrients from soil, topography and environmental attributes in the northern part of Ekiti State, Nigeria. **Remote Sensing Applications: Society and Environment,** v. 21. 2021. Doi : https://doi.org/10.1016/j.rsase.2020.100450. Acesso em 03 abr. 2024 .

LI, H.; LI, T.; GORDON, R.J.; ASIEDU, S.K.; HU, K. Strawberry plant fruiting efficiency and its correlation with solar irradiance, temperature and reflectance water index variation. **Environmental and Experimental Botany**, v. 68, n. 2, 2010. p. 165-174. doi: https://doi.org/10.1016/j.envexpbot.2009.12.001. Acesso em 03 abr. 2024.

LIU, R.; XU, F.; YU, W. Analysis of field-scale spatial correlations and variations of soil nutrients using geostatistics. **Environ Monit Assess** . v.188, n. 126, 2016. doi: https://doi.org/10.1007/s10661-016-5130-9. Aceso em: 03 abr. 2024.

MALAVOLTA, E.; VITTI, G.C.; OLIVEIRA, S.A. **Avaliação do estado nutricional das plantas: princípios e aplicações**. Piracicaba: Potafós, 1997. 319p.

MANLEY, M. Near-infrared Spectroscopy and Hyperspectral Imaging: Non-destructive Analysis of Biological Materials. **Chem. Soc. Rev**, v. 43, n.24, 2014. p. 8200-8214. doi:10.1039/C4CS00062E. Acesso em 03 abr. 2024.

MARSCHNER, H. **Mineral nutrition of higher plants London**: Academic Press, 1995. 889p.

MORITSUKA, N.; YANAI, J.; UMEDA, M.; KOSAKI, T. Spatial relationships among different forms of soil nutrients in a paddy field. **Soil Science and Plant Nutrition**. v. 50, n. 4, 2004. p. 565-573. doi:https://doi.org/10.1080/00380768.2004.10408513. Acesso em 03 abr. 2024.

PEARSON, K. Mathematical contributions to the theory of evolution. III. Regression, herefity and panmixia. **Philosophical Transactions of the Royal Society of London**. Series A, Containing Papers of a Mathematical or Physical Character, n. 187, 1896. p. 253-318.

PISSINATI, A.; MOREIRA, A.; SANTORO, P. H. Yield components and nutrients content in summer cover plants used in crop rotation in no-tillage system. **Communications in Soil Science and Plant Analysis**, n. 49, v. 13, 2018. p. 1604-1616. doi: https://doi.org/10.1080/00103624.2018.1474899

SHAPIRO, S.S.; WILK, M.B. An analysis of variance test for normality. **Biometrika** v. 52, n. 3/4, 1965. p. 591-611

SIMS, D. A.; GAMON, J. A. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. **Remote Sensing of Environment**, n. 81, v. 2-3, 2002. p. 337-354.

TAGLIAPIETRA, E. L.; ZANON, A. J.; STRECK, N. A. Optimum Leaf Area Index to Reach Soybean Yield Potential in Subtropical Environment. **Agronomy Journal,** v. 113, n. 5, p. 4447-4456, 2021

TAYADE, R.; YOON, J.; LAY, L.; KHAN, A.L.; YOON, Y.; KIM, Y. Utilization of Spectral Indices for High-Throughput Phenotyping. **Plants**, v. 11, 2022. p. 1712. https://doi.org/10.3390/plants11131712. Acesso em 03 abr. 2024

TONG, A.; HE, Y. Remote sensing of grassland chlorophyll content: Assessing the spatial-temporal performance of spectral indices. **2014 IEEE Geoscience and Remote Sensing Symposium**, Quebec City, QC, Canada, 2014, pp. 2846-2849, doi: 10.1109/IGARSS.2014.6947069.

VEIGA, M. D.; OLIVEIRA, P. T. S.; MENDONÇa, M. S. Soil physical properties under different grazing intensities in a tropical rangeland. **Revista Brasileira de Ciência do Solo**, n, 39, v. 6, 2015. p. 1560-1569.

VILLAMUELAS, M.; PÉREZ-GUTIÉRREZ, C.; GARCÍA-GIRÓN, J. A comprehensive analysis of vegetation indices from Sentinel-2 images for agriculture applications. **Remote Sensing,** v. 8, n. 10, 2016. 833 p.

VARIABILIDADE ESPACIAL DO SOLO EM VINHEDO: CONTRIBUIÇÕES DA PEDOLOGIA PARA AGRICULTURA DE PRECISÃO

DANIEL ALEXANDRE HEBERLE [1]; CAIO BUSTAMI ANDRADE [1]; GUSTAVO EDUARDO PEREIRA [1]; FELIPE DAMIN [1]; ALEXANDRE TEN CATEN [2]

[1]Bolsista. Rodovia Ulysses Gaboardi, 3000 - Curitibanos, SC, 89520-000. Universidade Federal de Santa Catarina; [2]Docente. Rodovia Ulysses Gaboardi, 3000 - Curitibanos, SC, 89520-000. Universidade Federal de Santa Catarina

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

O presente estudo investigou a variabilidade espacial do solo em vinhedos de altitude, destacando sua relevância para a produção de vinhos finos. A heterogeneidade do solo é um fator que influencia diretamente na uniformidade, qualidade e produtividade das uvas. A identificação de padrões e zonas homogêneas no solo, utilizando técnicas como a geoestatística, possibilita a implementação. Utilizando técnicas como geoestatística, foram identificados padrões e zonas homogêneas no solo, na qual possibilita a implementação de práticas agrícolas mais eficientes, incluindo a adubação em taxa variada conforme a variabilidade espacial do solo. Amostras de solo foram coletadas em diferentes profundidades e analisadas quanto a atributos como: teor de carbono orgânico, argila e soma de bases. Os resultados revelaram heterogeneidade pedológica, influenciada por fatores como material de origem, posição topográfica e processos de intemperismo. Essas variações têm implicações significativas na disponibilidade de nutrientes, retenção de água e desenvolvimento das raízes das plantas. A integração da pedologia com a viticultura de precisão é essencial para otimizar o manejo agrícola em vinhedos de altitude. Essa abordagem permite que os produtores tomem decisões mais assertivas e eficazes, visando aumentar a produtividade e garantir a sustentabilidade ambiental e econômica das operações agrícolas. A análise detalhada das características do solo, aliada às práticas de viticultura de precisão, possibilita a produção de vinhos finos de alta qualidade, refletindo o verdadeiro potencial da região de altitude e garantindo a excelência e autenticidade desses produtos no mercado vitivinícola.

PALAVRAS-CHAVE: Vinhedos de altitude; qualidade do solo; manejo pedológico

ABSTRACT

The present study investigated the spatial variability of soil in high-altitude vineyards, emphasizing its relevance to the production of fine wines. Soil heterogeneity is a factor that directly influences the uniformity, quality, and productivity of grapes. The identification of patterns and homogeneous zones in the soil, using techniques such as geostatistics, enables the implementation of more efficient agricultural practices, including variable-rate fertilization according to soil spatial variability. Soil samples were collected at different depths and analyzed for attributes such as organic carbon content, clay, and sum of bases. The results revealed pedological heterogeneity, influenced by factors such as parent material, topographic position, and weathering processes. These variations have significant implications for nutrient availability, water retention, and plant root development. The integration of pedology with precision viticulture is essential to optimize agricultural management in high-altitude vineyards. This approach allows producers to make more informed and effective decisions, aiming to increase productivity and ensure environmental and economic sustainability of agricultural operations. The detailed analysis of soil characteristics, combined with precision viticulture practices, enables the production of high-quality fine wines, reflecting the true potential of the high-altitude region and ensuring the excellence and authenticity of these products in the wine market.

KEYWORDS: ;

INTRODUÇÃO

A heterogeneidade espacial do solo em vinhedos para produção de vinho fino é um aspecto crucial a ser considerado devido ao impacto direto que possui na qualidade e produtividade das uvas. Estudos da variabilidade dos atributos do solo são essenciais para compreender fatores como: a distribuição de nutrientes, textura do solo e disponibilidade de água influenciam o desenvolvimento das videiras.

A variabilidade espacial dos atributos do solo, como destacado por diversos estudos (Noetzold et al., 2018), é influenciada por fatores como material de origem, relevo, clima, organismos e práticas de manejo do solo. A análise da variabilidade espacial dos atributos do solo por meio de técnicas como geoestatística é fundamental para identificar padrões e zonas homogêneas no solo (Nascimento et al., 2014).

Além disso, a aplicação de princípios da agricultura de precisão, como a adubação em taxa variada de acordo com a variabilidade espacial dos atributos do solo, é essencial para otimizar o manejo e a produtividade das videiras (Amado et al., 2009). Estudos como os de Souza et al. (2004) ressaltam a importância de compreender a variabilidade do solo para implementar práticas agrícolas mais eficientes e rentáveis. Portanto, a análise da variabilidade espacial dos atributos do solo em vinhedos é fundamental para direcionar estratégias de manejo adequadas (Silva et al., 2014), e garantir a sustentabilidade e qualidade da produção de vinho fino.

A pedologia desempenha um papel fundamental no estudo da variabilidade espacial em solos de videira, pois essa ciência se dedica à análise das propriedades físicas, químicas e biológicas do solo e à sua classificação em diferentes unidades. Através da pedologia, é possível compreender os fatores como: textura, estrutura, composição química e capacidade de retenção de água do solo variam espacialmente, influenciando diretamente o desenvolvimento das videiras e, consequentemente, a qualidade das uvas e do vinho produzido.

Estudos como o de Bernardi et al. (2014) destacam a importância da condutividade elétrica do solo na interpretação das variações de rendimento das culturas, demonstrando como atributos físico-químicos do solo podem afetar a produtividade das plantas. Além disso, a análise da variabilidade espacial dos atributos do solo, como mencionado por Mion et al. (2012), é essencial para identificar alternativas de manejo que minimizem os efeitos negativos da variabilidade do solo sobre a produtividade agrícola.

A geoestatística, técnica utilizada em estudos pedológicos, permite estabelecer modelos que descrevem a variabilidade espacial do solo, auxiliando na interpolação digital e na identificação de zonas homogêneas. A análise da variabilidade espacial dos atributos do solo em vinhedos, conforme destacado por Vieira et al. (2010), é essencial para o estabelecimento de mapas pedológicos. O objetivo desta pesquisa é analisar a variabilidade espacial dos atributos do solo em um vinhedo de altitude dedicado à produção de vinhos finos, destacando o papel da pedologia nesse contexto.

OBJETIVOS

O objetivo desta pesquisa é analisar a variabilidade espacial dos atributos do solo em um vinhedo de altitude dedicado à produção de vinhos finos, destacando o papel da pedologia nesse contexto.

MATERIAL E MÉTODOS

A área de estudo está situada em uma parcela de 0,4 hectares no município de Curitibanos (SC) (Figura 1), com coordenadas geográficas centrais de 27°12'18"S e 50°37'10"O. Neste local, são

cultivadas videiras da variedade Sauvignon Blanc para a produção de vinhos finos. O porta-enxerto utilizado no pomar é o Paulsen 110, com condução em espaldeira utilizando o sistema de cordão esporonado simples. A altitude da área experimental é de aproximadamente 921 metros acima do nível médio do mar. Os solos predominantes na área de estudo são Latossolos e Nitossolos em áreas mais planas, enquanto em áreas de relevo mais movimentado ocorrem Neossolos e Cambissolos (UBERTI, 2005).

A região é classificada como de clima Cfb, segundo a classificação de Köppen, o que indica um clima temperado, constantemente úmido, com verões amenos (ALVARES et al., 2013). A temperatura média anual varia de 15,8 a 17,9°C, com médias de temperaturas máximas variando de 22,3 a 25,8°C e mínimas de 10,8 a 12,9°C. A precipitação pluviométrica total anual pode variar de 1.460 a 1.820 mm (EMBRAPA, 2012).

Na área do pomar, foram georreferenciadas 68 plantas de videira com auxílio de um GNSS (Global Navigation Satellite System). As amostras de solo foram coletadas ao lado de cada planta marcada e georreferenciada, nas camadas de 0-20 e 20-40 cm, totalizando 136 amostras. As amostras coletadas foram secas ao ar, destorroadas e passadas em peneira com malha de 2 mm, sendo submetidas a análises físicas e químicas. Para o presente estudo, foram analisados o teor de carbono orgânico, teor de argila e Ca2+, Mg2+, Na+, K+, para cálculo da soma de bases, conforme metodologia preconizada por Tedesco et al. (1995).

A identificação dos tipos de solos na área de estudo foi realizada conforme o manual de descrição de solo (SANTOS et al., 2015) e classificada conforme os critérios estabelecidos pelo Sistema Brasileiro de Classificação de Solos (SANTOS et al., 2018). As análises com finalidade de classificar os solos foram: Fe2O3, Al2O3, SiO2, por Fluorescência de raios-X conforme descrito por Silva et al. (2020) e Ca2+, Mg2+, Na+, K+, Al3+, H++Al3+, pH, pH em KCl, carbono orgânico e textura (areia, silte e argila), conforme EMBRAPA (2017).

Com base nos teores de carbono, argila e soma de bases determinados em laboratório, foi elaborado o mapa de distribuição espacial da área avaliada. Para a espacialização dos dados, foi utilizado o algoritmo Natural Neighbour por meio do software SAGAGIS 7.8.2 (CONRAD et al., 2015).

A análise da variabilidade espacial dos atributos do solo permitirá direcionar estratégias de manejo adequadas, como a fertirrigação, visando garantir a sustentabilidade e qualidade da produção de vinho fino.

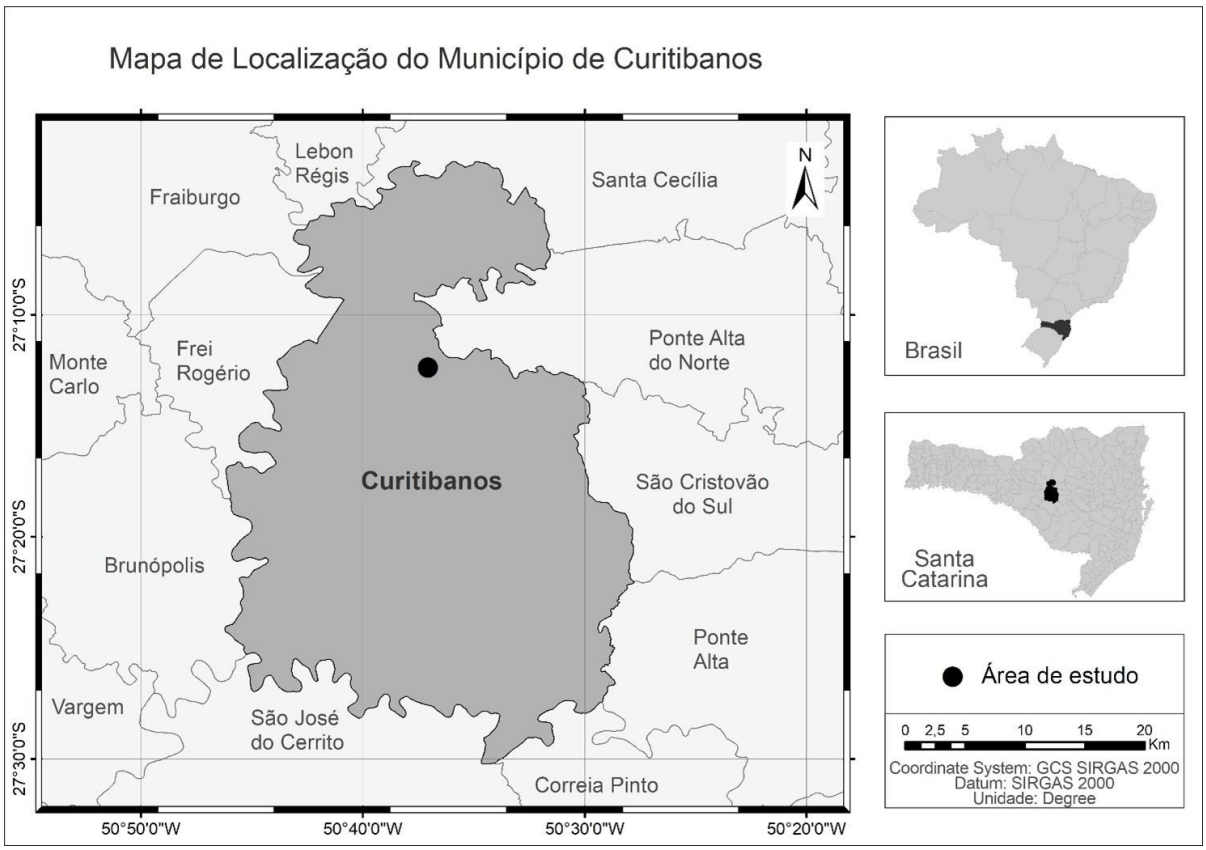


FIGURA 1. Mapa de localização da área de estudo, município de Curitibanos-SC.

RESULTADOS E DISCUSSÃO

A mudança lateral de solos, como exemplificado pela transição do Nitossolo Bruno Distroférrico típico (NBdf) para o Latossolo Vermelho Distroférrico típico (LVdf) e, posteriormente, para o Latossolo Bruno Distroférrico típico (LBdf) ao longo de um desnível de 15 metros em 100 metros, pode exercer um impacto significativo na viticultura. Essa alteração está intimamente ligada às variações nas características físicas e químicas do solo como: textura, capacidade de retenção de nutrientes e água, que desempenham um papel fundamental no desenvolvimento das plantas.

A transição entre os solos NBdf, LVdf e LBdf pode acarretar modificações na disponibilidade de nutrientes vitais para as plantas, como fósforo e potássio, devido às discrepâncias na capacidade de adsorção desses elementos pelos solos (Pierangeli et al., 2001; Almeida et al., 2003). Além disso, as variações na textura do solo podem influenciar diretamente na retenção de água e na drenagem, afetando assim o abastecimento hídrico disponível para as plantas (Oliveira et al., 2010). Isso também pode resultar em diferenciações no desenvolvimento do sistema radicular, dado que um mesmo pomar pode se deparar com três diferentes tipos de solos, cada qual com suas peculiaridades físicas.

É relevante salientar que a composição e diversidade das comunidades bacterianas do solo podem ser impactadas durante as transições entre os tipos de solos, o que, por sua vez, pode influenciar indiretamente na saúde e desenvolvimento das plantas cultivadas (Aira et al., 2022).

Dessa forma, essas mudanças na composição e características dos solos podem afetar a viticultura de múltiplas maneiras, incluindo a disponibilidade de nutrientes, retenção de água e interações microbiológicas no solo. Tais considerações ressaltam a importância de avaliar minuciosamente as características do solo ao planejar e gerenciar vinhedos, visando garantir condições ideais para o crescimento e produção de uvas de qualidade.

A análise dos três perfis de solo revela uma heterogeneidade pedológica na área de estudo (Figura 2). No perfil 1 (NBdf), observamos uma sequência que inicia com um horizonte Ap, com características de solo Bruno-escuro, apresentando uma textura argilosa e blocos subangulares pequenos e fortes. Este horizonte transita gradualmente para um horizonte A1, mantendo as mesmas características pedológicas, porém com uma tonalidade mais escura e uma transição plana. O horizonte AB, por sua vez, exibe características de solo Bruno-escuro e Muito Argiloso, com blocos subangulares pequenos e moderados e uma transição difusa e plana. A profundidade maior revela horizontes Bt1 e Bt2, com características semelhantes ao AB, porém com a presença de cerosidade moderada e forte, respectivamente, e uma transição difusa e plana.

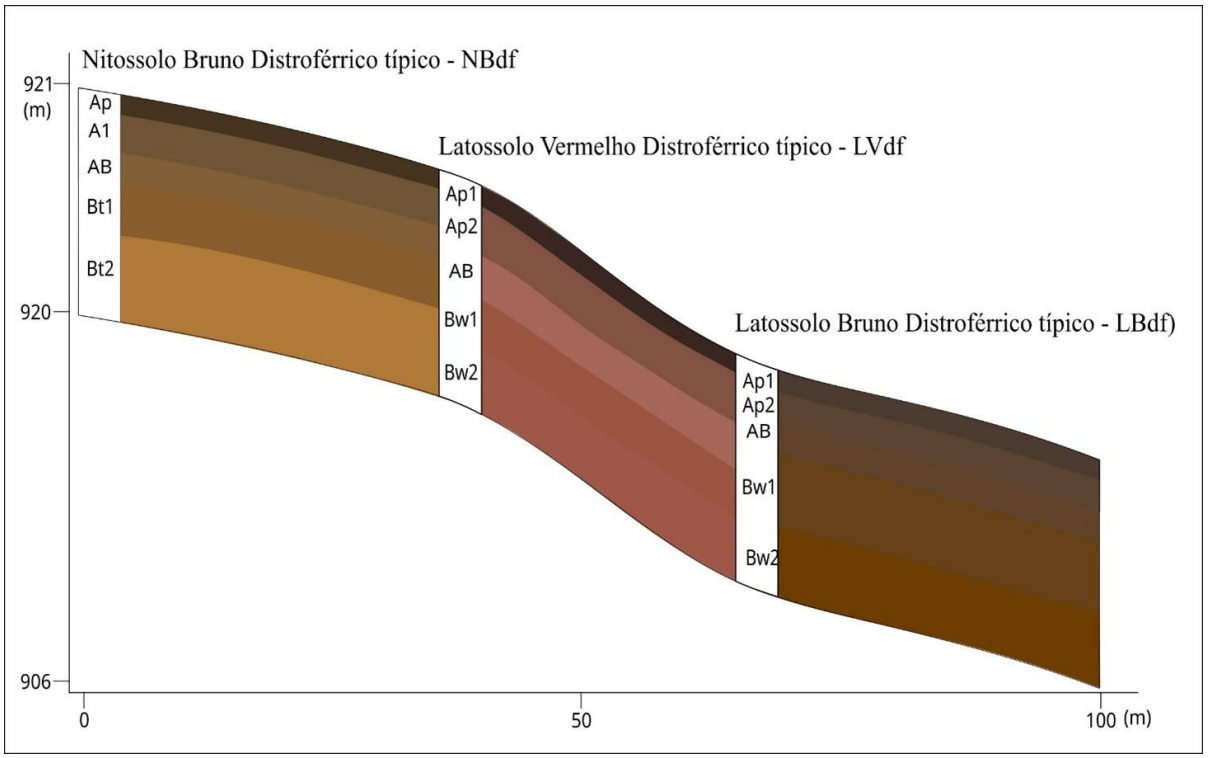


FIGURA 2. Perfil topográfico da área de estudo com mudança lateral de solos ao longo do vinhedo.

No perfil 2 (LVdf), o horizonte Ap é composto por um solo Bruno muito escuro, com blocos subangulares de tamanho médio e moderado. A transição para o horizonte A é gradual, mantendo a textura argilosa e blocos subangulares de tamanho médio e moderado. O horizonte BA apresenta características de solo Bruno-avermelhado-escuro e Muito Argiloso, com blocos subangulares pequenos e moderados. As camadas mais profundas, representadas pelos horizontes Bw1 e Bw2, exibem uma transição difusa e plana, mantendo as características de solo Bruno-avermelhado-escuro, Muito Argiloso e blocos subangulares de tamanho médio a fraco.

Já no perfil 3 (LBdf), o horizonte Ap1 mostra características de solo Bruno-avermelhado-escuro, com blocos subangulares de tamanho médio e moderado. A transição para o horizonte Ap2 é marcada por uma camada revolvida e alterada, mantendo uma textura argilosa e blocos subangulares de tamanho médio e fraco. O horizonte AB exibe características semelhantes ao Ap2, porém com a presença de pouca cerosidade. As camadas mais profundas, representadas pelos horizontes Bw1 e Bw2, apresentam uma transição difusa e plana, mantendo as características de solo Bruno-escuro, Muito Argiloso e blocos subangulares de tamanho médio a fraco, além da presença de pouca cerosidade.

Essas variações nos perfis de solo refletem a influência de fatores como material de origem, posição topográfica e processos de intemperismo, destacando a complexidade pedológica da área de estudo e a importância de considerar essas diferenças no manejo e planejamento agrícola. A integração entre

a pedologia e viticultura de precisão proporciona um conhecimento importante a ser utilizado nas fases de planejamento, implantação e manejo da cultura.

No que tange à variação espacial dos atributos das camadas 0-20 e 20-40 cm, os teores de carbono orgânico e argila variaram significativamente entre as camadas. A matéria orgânica aumentou na porção mais baixa (perfil 1) do vinhedo em ambas as camadas, enquanto o teor de argila aumentou na porção mais elevada (perfil 3). Na porção central, a retenção de água é menor devido à inclinação do terreno, o que faz com que a água escoe mais rapidamente do que na porção mais baixa. Com isso, o acúmulo de carbono orgânico aumentou na porção mais baixa, uma vez que, com maior umidade, há menor mineralização do carbono. Por outro lado, nessa mesma porção mais baixa o teor de argila é menor. Ambos os atributos são importantes para o manejo e devem ser considerados na tomada de decisão.

Quanto ao atributo Soma de Bases, que reflete a fertilidade do solo, é possível observar a ocorrência de regiões com valores mais elevados, acima de 10 cmolc kg^{-1} na camada de 0-20 cm e valores acima de 7 cmolc kg^{-1} na camada de 20-40 cm. O que demonstra variação espacial em 3 dimensões, considerando a zona de maior parte das raízes de frutíferas. A importância dos nutrientes nas camadas de 0-20 cm e 20-40 cm do solo é crucial para a adubação adequada de frutíferas, como a videira, que se estende até 40 cm de profundidade. Estudos indicam que a disponibilidade de nutrientes nessas camadas do solo desempenha um papel fundamental no desenvolvimento das plantas (Brunetto et al., 2015), especialmente em camadas mais profundas do solo, como a 20-40 cm (Barreto et al., 2022).

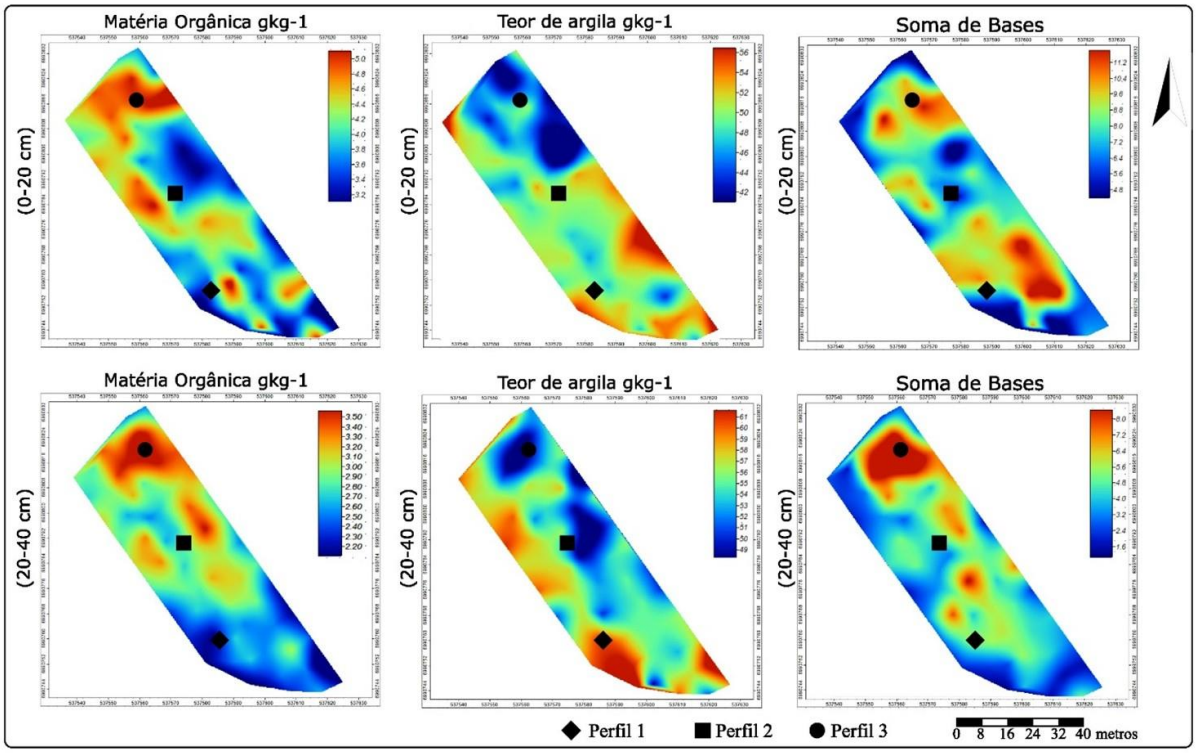


FIGURA 3. Mapas de interpolações utilizando o algoritmo Natural Neighbour para os atributos matéria orgânica, argila e soma de bases nas camadas de 0-20 e 20-40 cm.

Além disso, a distribuição das raízes das plantas, como as videiras, pode variar de acordo com a disponibilidade de água e nutrientes em diferentes profundidades do solo (MELO et al., 2016). A água e os nutrientes presentes nas camadas de 0-20 cm e 20-40 cm são essenciais para o crescimento das raízes e, consequentemente, para a absorção eficiente de nutrientes pelas plantas. Portanto, a adubação adequada nessas camadas, considerando a variação observada no solo estudado, é fundamental para garantir o suprimento necessário de nutrientes para as videiras ao longo de seu ciclo de crescimento.

Em suma, a análise da disponibilidade de nutrientes nas camadas de 0-20 cm e 20-40 cm do solo é essencial para a adubação eficaz da videira, que requer nutrientes distribuídos uniformemente para todas as plantas (MELO et al., 2012) A compreensão da distribuição espacial dos atributos do solo permite entender, em parte, as características físicas e químicas que as raízes encontrarão na área de estudo, auxiliando na tomada de decisão e otimizando a adubação para promover o crescimento e a produtividade das culturas.

No contexto da fruticultura de precisão, a análise detalhada das características pedológicas se revela como um elemento fundamental para otimizar o manejo agrícola e promover o crescimento saudável das culturas, como é o caso das vinhas em vinhedos.

A heterogeneidade pedológica, influenciada por fatores como material de origem, posição topográfica e processos de intemperismo, têm implicações significativas, pois afetam diretamente a disponibilidade de nutrientes essenciais, a retenção de água e o desenvolvimento das raízes das plantas.

A compreensão das variações nos perfis de solo ao longo do terreno e sua relação com a disponibilidade de nutrientes e água proporciona insights valiosos para a tomada de decisão estratégica no campo.

Nesse sentido, a fruticultura de precisão emerge como uma abordagem estratégica para maximizar a produtividade e a qualidade das safras, utilizando tecnologias avançadas, como sensoriamento remoto, sistemas de informação geográfica (SIG) e monitoramento da variabilidade do solo, para otimizar a aplicação de insumos agrícolas.

Ao integrar o conhecimento detalhado das características do solo com as práticas de fruticultura de precisão, os agricultores podem tomar decisões mais assertivas e eficazes, visando não apenas aumentar a produtividade, mas também garantir a sustentabilidade ambiental e econômica de suas operações agrícolas.

Na cultura da videira para produção de vinhos finos de altitude, a análise minuciosa das características do solo desempenha um papel decisivo na busca pela excelência na qualidade da uva e, consequentemente, do vinho produzido. A compreensão das variações pedológicas ao longo do vinhedo, especialmente em terrenos de altitude, é essencial para garantir condições ideais de crescimento e desenvolvimento das videiras, bem como para otimizar o manejo agrícola e promover a sustentabilidade do vinhedo.

A integração da pedologia com a viticultura de precisão desempenha um papel fundamental na produção de vinhos finos de altitude. A pedologia, que estuda o solo em seus aspectos físicos, químicos e biológicos, é essencial para compreender as características do terroir, ou seja, do ambiente onde as uvas são cultivadas, influenciando diretamente a qualidade e o sabor dos vinhos.

CONCLUSÃO

A integração da pedologia com a viticultura de precisão desempenha um papel fundamental na produção de vinhos finos de altitude ao permitir o conhecimento dos aspectos físicos e químicos do solo, essencial para compreender as características do ambiente onde as uvas são cultivadas.

Com a integração os produtores de vinho podem otimizar o manejo do vinhedo, adequando as práticas agrícolas às condições específicas do solo e do clima da região de altitude.

A combinação da expertise da pedologia na análise do solo, juntamente com as tecnologias de precisão da viticultura é essencial para potencializar a produção de vinhos finos de altitude, garantindo a excelência e a autenticidade desses produtos no mercado vitivinícola.

AGRADECIMENTOS

À Fundação de Amparo à Pesquisa de Santa Cataria - FAPESC e a Vinícola Berto Aguiar.

REFERÊNCIAS

AIRA, M.; PEREZ-LOSADA, M.; CRANDALL, K.A.; DOMINGUEZ, J. Composition, structure and diversity of soil bacterial communities before, during and after transit through the gut of the earthworm aporrectodea caliginosa. **Microorganisms**, 10(5), 1025, 2022.

ALMEIDA, J.A.; TORRENT, J.; BARRÓN, V. Cor de solo, formas do fósforo e adsorção de fosfatos em latossolos desenvolvidos de basalto do extremo-sul do brasil. **Revista Brasileira de Ciência do Solo**, 27(6), 985-1002, 2003.

ALVARES, C. A.; STAPE, J.L; SENTELHAS, P.C.; MORAES, J.L.G.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p.711-728, 201

AMADO, T.J.C.; PES, L.Z.; LEMAINSKI, C.L.; CHENATO, R.B. Atributos químicos e físicos de latossolos e sua relação com os rendimentos de milho e feijão irrigados. **Revista Brasileira de Ciência do Solo**, 33(4), 831-843, 2009.

BARRETO, C. F.; ANTUNES, L. E. C.; NOVRASKI, R.; BENATI, J. A.; FERREIRA, L. V.; NAVA, G. Potassium fertilization and its impact on production and mineral composition of peach trees. **Revista Brasileira de Fruticultura**., Jaboticabal, v. 44, n. 4: (e-208), 2022.

BERNARDI, A.C.C; RABELLO, L.M.; INAMASU, R.Y.; GRAGO, C.R.; ANDRADE, R.G. Variabilidade espacial de parâmetros físico-químicas do solo e biofísicos de superfície em cultivo do sorgo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, 18(6), 623-630, 2014.

BRUNETTO, G.; MELO, G. W. B.; TOSELLI M.; QUARTIERI, M.; TAGLIAVINI, M. The role of mineral nutrition on yields and fruit quality in grapevine, pear and apple. **Revista Brasileira de Fruticultura** , v. 37, p. 1089-1104, 2015.

CONRAD, O., BECHTEL, B., BOCK, M., DIETRICH, H., FISCHER, E., GERLITZ, L., WEHBERG, J., WICHMANN, V., AND BÖHNER, J. System for Automated Geoscientific Analyses (SAGA). **Geosci. Model Dev**. v. 2.1.4, 1991-2007, 2015.

EMBRAPA. Atlas climático da Região Sul do Brasil: Estados do Paraná. Santa Catarina e Rio Grande do Sul. Pelotas: Embrapa Clima Temperado; Colombo: **Embrapa Florestas**. 2012.

MELO, G.W.B.; SETE, P.B.; AMBROSINI, V.G.; FREITAS, R.F.; BASSO, A.; BRUNETTO, G. Nutritional status, yield and composition of peach fruit subjected to the application of organic compost. **Acta Sci. Agron**. 38(1). 403-409, 2016.

MELO, G. W. B., BRUNETTO, G., BASSO, A., & HEINZEN, J. Resposta das videiras a diferentes modos de distribuição de composto orgânico no solo. **Revista Brasileira de Fruticultura**. 34(2), 493-503. 2012.

MION, R.L.; NASCIMENTO, E.M.S.; SALES, F.A.L.; SILVA, S.F.; DUARTE, J.M.L.; SOUZA, B.M. Variabilidade espacial da porosidade total, umidade e resistência do solo à penetração de um argissolo amarelo. **Semina Ciências Agrárias**, 33(6), 2057-2066, 2012.

NASCIMENTO, P.S.; SILVA, J.A.; COSTA, B.R.S.; BASSOI, L.H. Zonas homogêneas de atributos do solo para o manejo de irrigação em pomar de videira. **Revista Brasileira de Ciência do Solo**, 38(4), 1101-1113. 2014.

NOETZOLD, R.; SILVA, L.M; SCHONINGER, E.L.; TOMÉ, P.C.D.T.; ALVES, M.C. Variabilidade espacial e temporal de atributos químicos do solo durante cinco safras. **Revista Brasileira de Geomática**, 6(4), 328, 2018.

OLIVEIRA, L.A.; GONÇALVEZ, R.M.; MARTINS, F.P. Contraste de condutividade hidráulica em solos de texturas arenosa e argilosa encontrados nos tributários da margem esquerda do rio tijuco, municipio de ituiutaba, estado de minas gerais, brasil. **Caminhos de Geografia**, 11(33), 230-243.2010

PIERANGELI, M.A.P.; GUILHERME, L.R.G.; OLIVEIRA, L.R.; CURI, N. & SILVA, M.L.N. Efeito da força iônica da solução de equilíbrio sobre a adsorção/dessorção de chumbo em Latossolos brasileiros. **Pesq. Agropec. Bras.**, 36:1077-1084, 2001.

SANTO, R.D.; SANTOS, H.G.; KER, J.C.; ANJOS, L.H.; SHIMIZU, S.H. **Manual de Descrição e Coleta de Solo no Campo**. Sociedade Brasileira de Ciência do Solo.2015.

SANTOS, H.G. JACOMINE, P..K.T.; ANJOS, L.H.C.; OLIVEIRA, V.A.; LUMBRERAS, J.F.; COELHO.; M.R.; ALMEIDA, J.A.; ARAUJO FILHO, J.C.; OLIVEIRA, J.B.; CUNHA, T.J.F. **Sistema Brasileiro de Classificação de Solos**, Embrapa Solos. Rio de Janeiro. 2018, p. 356

SILVA., D.J.; SILVA, A.O.; BASSOI, L.H.; COSTA, B.S.; TEIXEIRA, R.P.; SOUZA, D.M. Adubação orgânica e fertirrigação potássica em videira 'syrah' no semiárido. **Irriga**, 1(1), 168, 2014

OLIVEIRA SILVA, M. DE, VELOSO, C. L.; NASCIMENTO, D. L. DO; OLIVEIRA, J. DE, PEREIRA, D. DE F.; COSTA, K. D.S;. Indicadores químicos e físicos de qualidade do solo / Chemical and physical indicators of soil quality. **Brazilian Journal of Development**, 6(7), 47838-47855.2020.

SOUZA, Z.M.; MARQUES JUNIOR, J. PEREIRA, G.T.; MOREIRA, L.F. Variabilidade espacial do ph, ca, mg e v% do solo em diferentes formas do relevo sob cultivo de cana-de-açúcar. **Ciência Rural**, 34(6), 1763-1771, 2004.

TEDESCO, M. J.; GIANELLO, C.; BISSANI, C.A.; BOHNEN, H. VOLKWEISS, S.J. Análise de solo, plantas e outros materiais. **Boletim Técnico Nº5.** Porto Alegre. UFRGS/FA/DS, 1995. 174 p.

TEIXEIRA, P.C.; DONAGEMMA, G.K.; FONTANA, A.; TEIXEIRA, W.G. **Manual de métodos de análise de solo.** 3. ed. Brasília, DF: Embrapa, 2017. 574 p.

UBERTI, A. A. A; **Santa Catarina: proposta de divisão territorial e Regiões Edafoambientais**. [Tese]. Florianópolis: UFSC, 2005.

VIEIRA, S.R.; CARCIA, M.A.G.; CONZALEZ, A.P.; SIQUEIRA, G.M. Variabilidade espacial e temporal do teor de água do solo sob duas formas de uso. **Bragantia**, 69(1), 181-190, 2010.

VARIABILIDADE ESPACIAL DA PRODUTIVIDADE DE MILHO PARA SILAGEM POR DIFERENTES MODELOS DE SEMIVARIOGRAMA

ANAIDE CAROLANE DA SILVA SANTOS [1]; RICHARDSON SOARES DE SOUZA MELO [2]; Marcelo Coelho Furtado [3]; GABRIEL FERREIRA DE OLIVEIRA [4]; MIGUEL JULIO MACHADO GUIMARAES [2]

[1]Graduanda em Agronomia . BR-230, São Raimundo das Mangabeiras - MA, 65840-000. Instituto Federal de Educação, Ciência e Tecnologia do Maranhão; [2]Engº Agrônomo, Professor Dr.. BR-230, São Raimundo das Mangabeiras - MA, 65840-000. Instituto Federal de Educação, Ciência e Tecnologia do Maranhão; [3]Engº Agrônomo. BR-230, São Raimundo das Mangabeiras - MA, 65840-000. Instituto Federal de Educação, Ciência e Tecnologia do Maranhão; [4]Graduando em Agronomia . BR-230, São Raimundo das Mangabeiras - MA, 65840-000. Instituto Federal de Educação, Ciência e Tecnologia do Maranhão

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

O objetivo desse trabalho foi verificar qual modelo de kigragem melhor se ajusta para representar a variabilidade da produção do milho para silagem. O experimento foi desenvolvido na Fazenda Agrícola do Instituto Federal do Maranhão, Campus São Raimundo das Mangabeiras. A área experimental avaliada continha 3,0 ha de milho cultivado em sistema de sequeiro. A produção de biomassa seca foi avaliada na fase fenológica R3, na ocasião foram realizadas amostragens em 40 pontos georreferenciados, em um grid de 30 x 30 m. Em cada ponto de coleta colheu-se três plantas, as quais foram utilizadas para estimar a produtividade de Biomassa Seca de cada ponto de coleta (t ha^{-1}). Os valores de efeito pepita (Co), patamar (Co+C1), contribuição (C1) e do alcance (Ao) foram obtidos através dos semivariogramas de cada camada estudada, estimados pelo complemento Smart-MAP do software QGIS. Com os dados krigados foram gerados mapas de variabilidade. Considerando os resultados obtidos, é possível concluir que o modelo de semivariograma linear com patamar apresenta um melhor ajuste na análise da variabilidade espacial da produtividade de biomassa seca de milho para silagem.

PALAVRAS-CHAVE: Geoprocessamento; *Zea mays* L.; geoestatística

ABSTRACT

The aim of this work was to find out which kriging model best represents the variability of corn production for silage. The experiment was carried out on the Agricultural Farm of the Federal Institute of Maranhão, São Raimundo das Mangabeiras Campus. The experimental area evaluated contained 3.0 ha of maize grown in a rainfed system. Dry biomass production was assessed at the R3 phenological stage, when samples were taken at 40 georeferenced points on a 30 x 30 m grid. Three plants were harvested at each collection point, which were used to estimate the dry biomass productivity of each collection point (t ha-1). The nugget effect (Co), plateau (Co+C1), contribution (C1) and range (Ao) values were obtained from the semivariograms of each layer studied, estimated using the Smart-MAP add-on in the QGIS software. Variability maps were generated from the kriged data. Considering the results obtained, it can be concluded that the linear semivariogram model with a plateau is the best fit for analyzing the spatial variability of the dry biomass yield of corn for silage.

KEYWORDS: ;

INTRODUÇÃO

A produção de milho *(Zea mays* L) tem relevância global devido ao seu elevado rendimento e teor nutricional. É um dos cereais mais produzidos e consumidos em todo o mundo. É muito utilizado para a produção de silagem, destinada à dieta de animais ruminantes, cerca de 1,5 milhões de hectares

de milho é destinado à produção de silagem, com valor total produtivo de 40 milhões de toneladas de matéria seca (IBGE, 2017). Diversas plantas forrageiras, tanto perenes quanto anuais, podem ser utilizadas na produção de silagem, mas o milho se destaca como uma das culturas mais utilizadas no Brasil para esse processo, devido ao seu alto rendimento de material vegetal fresco, à qualidade da fermentação e à preservação do valor nutritivo do material ensilado. O milho também oferece outras vantagens, como custos operacionais de produção reduzidos e uma boa aceitação pelos animais (SCHELER, CAVICHIOLI, 2021).

A produção de milho se alastra por toda a região Nordeste do Brasil, representando um dos principais produtos agrícolas na área. O milho desempenha um papel importante na geração de renda dos produtores agrícola. Para a produção de silagem é essencial selecionar uma variedade de milho adequada e um dos principais critérios a serem considerados é a produtividade de biomassa, pois isso interfere na capacidade de dimensionar os silos e contribui nos custos destinados à implantação da cultura. Portanto, estudos que possam ajudar a prever esses índices produtivos se tornam importantes para estas tomadas de decisão (SANTOS et al.,2010).

A importância da biomassa na produção de silagem é essencial, pois ela constitui a matéria-prima que fornece os elementos nutricionais essenciais para a alimentação dos animais. Avaliar a biomassa através de métodos convencionais demanda muita mão obra, equipamentos sofisticados e de custo elevado (JUNIOR et. al., 2021). Em várias regiões isso se torna impraticável, devido aos custos elevados e à necessidade de mão de obra, onde a utilização de informações obtidas por meio de Sensoriamento Remoto (SR) se torna uma alternativa viável para tentar prever a biomassa através da análise da cobertura vegetal, permitindo acompanhar as contínuas mudanças no crescimento e acúmulo de biomassa que ocorrem durante o desenvolvimento da planta. O SR é uma técnica que possibilita informações de um objeto sem o toque físico (FASSNACHT et al., HENTZ, 2014). Essa técnica possibilita análise da biomassa de forma mais acessível e com menor custo.

Associado às técnicas de SR, uma das maneiras para a análise do comportamento da população das plantas no terreno é o estudo da variabilidade espacial destas na área, visando a mensuração das diferenças e igualdade espaciais. No entanto, diversos são os modelos de interpolação que podem ser utilizados na análise da variabilidade espacial da produtividade dos cultivos agrícolas.

OBJETIVOS

Com isto, O objetivo desse trabalho foi verificar qual modelo de kigragem melhor se ajusta para representar a variabilidade da produção do milho para silagem.

MATERIAL E MÉTODOS

O experimento foi desenvolvido na Fazenda Agrícola do Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, Campus São Raimundo das Mangabeiras. O clima da região, segundo a classificação de Köppen, é do tipo Aw, quente com estação seca no inverno e úmida no verão. A temperatura média anual está em torno de 26.4 °C e a média anual de precipitação é de 1157 mm. O solo do local experimental foi classificado como Latossolo Amarelo distrófico (SILVA, 2018). A área experimental com 3,0 hectares, foi implantada com a variedade de milho BM 3066, com espaçamento de 0,20 m entre plantas e 0,40 m entre linhas no mês de janeiro de 2023. No preparo de solo, o mesmo foi corrigido utilizando de calcário na dose de 1,4 t ha^{-1}, a adubação consistiu em ureia (50 kg ha^{-1}), superfosfato simples (667 kg ha^{-1}), potássio (70 kg ha^{-1}) no plantio e uma adubação de cobertura utilizando ureia (334 kg ha^{-1}) e cloreto de potássio (140 kg ha^{-1}), o manejo de pragas e doenças foram realizados conforme as recomendações comerciais para a cultura do milho.

Para determinar a produtividade do milho foram realizadas amostragens em 40 pontos georreferenciados dentro da área de cultivo, em um grid de 30 x 30 m. Os pontos de coleta foram georreferenciados utilizando o método posicionamento relativo cinemático, seguindo as Especificações e Normas para Levantamentos Geodésicos Associados ao Sistema Geodésico Brasileiro (IBGE, 2017). Para isto, foi utilizado um par de aparelhos GNSS do modelo FOIF A30, com acurácia de 10 mm +1 ppm para horizontal e 20 mm +1 ppm na vertical, no modo *Real Time Kinematic* (RTK).

Em cada ponto de coleta colheu-se três plantas, as quais foram colocadas em sacos de papel e direcionadas a uma estufa de circulação forçada de ar a 65 °C por um período suficiente para obtenção do peso constante. Em seguida o material foi pesado em balança analítica com precisão de 0,000. Após a pesagem, os valores de produção foram multiplicados pelo estande da área para determinar a produtividade (t ha^{-1} de Biomassa Seca) de cada ponto de coleta. Os valores de efeito pepita (Co), patamar (Co+C1), contribuição (C1) e do alcance (Ao) foram obtidos através dos semivariogramas de cada camada estudada, estimados pelo complemento Smart-MAP do software QGIS. Com os dados krigados foram gerados mapas de variabilidade. O grau de dependência espacial (GDE %) foi obtido conforme Cambardella et al. (1994).

RESULTADOS E DISCUSSÃO

Analisando inicialmente o coeficiente de variação (C.V.) obtido por meio da análise estatística descritiva dos conjuntos de dados de produtividade (Tabela 1), verificou-se valor de 22,67, o que demonstra média variabilidade (20% ≤ C.V. ≤ 30%) (GOMES, 2000), significa que os dados apresentam uma relativa homogeneidade dos dados. Observa-se também valores negativos de assimetria e curtose, o que não caracteriza normalidade dos dados, segundo (CARVALHO; SILVEIRA; VIEIRA, 2002), valores teóricos de assimetria e curtose entre 0 e 3, indicam a distribuição normal dos dados. Essa determinação é importante uma vez que a krigagem apresenta melhores resultados quando a normalidade dos dados é satisfeita (CARVALHO; SILVEIRA; VIEIRA, 2002). Na Tabela 1, podemos observar que a produtividade média do experimento alcançou resultados satisfatórios de produtividade de matéria seca, chegando a uma média de 22,044 t/ha, sendo superior a valores encontrados por Pereira et. al, (2017), onde estudando características agronômicas na produção de silagem verificou produtividade média de matéria seca 13,296 kg ha^{-1}.

TABELA 1. Estatística descritiva da produtividade de milho para silagem.

Medidas Estatísticas	Produtividade
Média	24,044
Erro padrão	0,862
Mediana	24,125
Desvio padrão	5,453
Curtose	-0,676
Assimetria	-0,108
Mínimo	11,250
Máximo	33,750

Quando avaliados os modelos de krigagem avaliados (Tabela 2), pode-se observar que os menores valores da raiz quadrada do erro médio quadrático (RMSE), com 7,26, e o maior coeficiente de determinação (R^2), com 0,95, foram registrados no modelo linear com patamar, indicando assim um melhor ajuste deste modelo na representação dos dados avaliados. Ao analisar este modelo, verificou-se alcance (Ao) de 59,84m e um grau de dependência espacial (GDE) de 28,44%. Segundo a interpretação de Cambardella et al. (1994), a produtividade de biomassa seca do milho, avaliada neste estudo, possui moderada dependência espacial, pois o semivariograma que melhor se ajustou apresenta moderada relação, variando entre 25 a 75%. Com base nestes resultados, infere-se que o grid de 30 x 30 m utilizado na coleta das amostras suficiente para expressar a variabilidade espacial para esta variável.

TABELA 2. Modelos e parâmetros estimados dos semivariogramas experimentais da produtividade de milho para silagem.

Modelo	[1]Co	Cl	Co+Cl	Ao (m)	RMSE	R^2	GDE (%)
Linear	19,13	10,43	29,56	80,64	48,83	0,64	64,72
Linear com Patamar	8,88	22,34	31,22	59,84	7,26	0,95	28,44
Exponencial	0,00	32,53	32,53	83,89	18,02	0,87	0,00
Esférico	2,11	29,03	31,14	67,92	9,65	0,93	6,79
Gaussiano	8,89	22,46	31,35	62,03	11,91	0,91	28,35

[1]Co = efeito pepita; C1 = contribuição ou variância estrutural; (Co+C1) = variância total; Ao = alcance; GDE = Grau de dependência espacial.

A Figura 1 apresenta os semivariogramas e os mapas de interpolação confeccionados por diferentes modelos de krigagem. Ao utilizar uma configuração de falsa-cor para representar os dados de produtividade de biomassa seca de milho para silagem pode-se observar que os mapas apresentaram grande similaridade visual entre os diferentes modelos estatísticos.

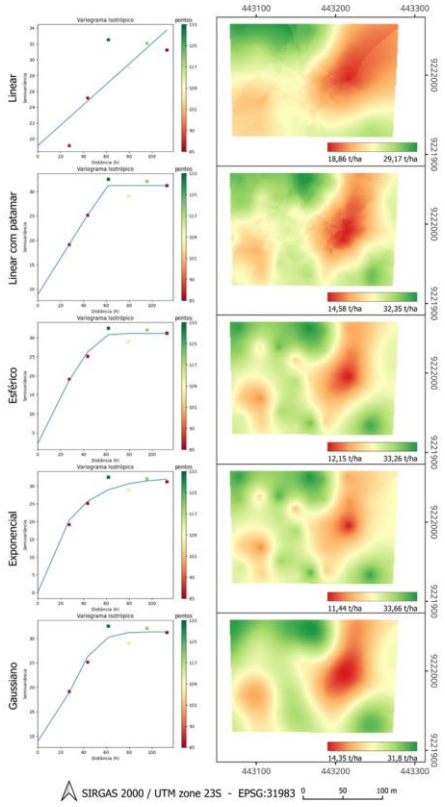


FIGURA 1. Semivariogramas e mapas de krigagem da produtividade de milho em sequeiro no sul do Maranhão.

CONCLUSÃO

Considerando os resultados obtidos, é possível concluir que o modelo de semivariograma linear com patamar apresenta um melhor ajuste na análise da variabilidade espacial da produtividade de biomassa seca de milho para silagem.

AGRADECIMENTOS

Ao Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, Campus São Raimundo das Mangabeiras, pelo apoio institucional.

REFERÊNCIAS

CAMBARDELLA, C. A.; MOORMAN, T.B.; NOVAK, J. M.; PARKIN, T. B.; KARLEN, D. L.; TURCO, R. F. & KONOPKA, A. E. Field-scale variability of soil properties in Central Iowa soils. Soil Science. Society. Am. J., 58:1501-1511, 1994.

CARVALHO, J. R. P.; SILVEIRA, P. M. & VIEIRA, S. R. Geoestatística na determinação da variabilidade espacial de características químicas do solo sob diferentes preparos. Pesquisa Agropecuária Brasileira, v. 37, p. 1151-1159,2002. http://dx.doi.org/10.1590/S0IOO-204X2002000800013.

GOMES, F. P. Curso de estatística experimental. 14.ed. Piracicaba: USP/ESALQ, 2000. 477 p.

PEREIRA, L. B., MACHADO, D. S., ALVES, D. C., Fº., BRONDANI, I. L., SILVA, V. S. DA, ARGENTA, F. M. BORCHATE, D. Características agronômicas da planta e produtividade da

silagem e grãos de milho submetido a diferentes arranjos populacionais. Magistra, v. 29, n. 1, 18-27, 2017.

IBGE - Instituto Brasileiro de Geografia e Estatística. Especificações e Normas para Levantamentos Geodésicos Associados ao Sistema Geodésico Brasileiro. Rio de Janeiro: Ministério do Planejamento, Desenvolvimento e Gestão, 2017.

SCHELER, E. D.; CAVICHIOLI, F. A. VIABILIDADE DE SILAGEM DE MILHO PARA

O GADO LEITEIRO. Revista Interface Tecnológica, [S. l.], v. 18, n. 1, p. 265-275, 2021. DOI: 10.31510/infa.v18i1.1095. Disponível em: https://revista.fatectq.edu.br/interfacetecnologica/article/view/1095. Acesso em: 12

set. 2023.

SANTOS, R. D. et al. Características agronômicas de variedades de milho para produção de silagem. Acta Scientiarum. Animal Sciences, v. 32, n. 4, p. 367-373, 2010.

JUNIOR, A. S. A. et al. Estimativa da biomassa de milho por imagens RGB de drones. Embrapa Meio-Norte. Boletim de pesquisa e desenvolvimento, 140. p. 41. Teresina: Embrapa Meio-Norte, 2021.

FASSNACHT, F. E. et. al. Importance of sample size, data type and prediction method for remote sensing-based estimations of aboveground forest biomass. Remote Sensing of Environment, v. 154, p. 102-114, Nov. 2014.

SILVA, J. F. Caracterização dos solos do Instituto Federal do Maranhão, Campus São Raimundo das Mangabeiras, região sul-maranhense. Dissertação de mestrado. Universidade Estadual Paulista - UNESP. Câmpus de Jaboticabal -

SP. 2018.

USO DE MAPAS DE DIAGNÓSTICO PARA O ACOMPANHAMENTO DA CONCENTRAÇÃO FOLIAR DE POTÁSSIO NA CULTURA DA SOJA

Aline Lampert Dutra [1]; André Müllich [2]; Luciano Zucuni Pes [3]; Ivan Carlos Maldaner [3]; Marcelo Silveira de Farias [3]

[1]Bolsista. Av. Roraima nº 1000 Cidade Universitária Bairro - Camobi, Santa Maria - RS, 97105-900. Colégio Politécnico da Universidade Federal de Santa Maria; [2]Bolsista. Av. Roraima nº 1000 Cidade Universitária Bairro - Camobi, Santa Maria - RS, 97105-900. Universidade Federal de Santa Maria; [3]Docente. Av. Roraima nº 1000 Cidade Universitária Bairro - Camobi, Santa Maria - RS, 97105-900. Colégio Politécnico da Universidade Federal de Santa Maria

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

No uso das ferramentas disponíveis na Agricultura de Precisão, tem-se como uma das temáticas a elaboração de mapas que representam a realidade de um determinado talhão. O potássio (K) é o segundo nutriente mais exportado pela cultura da soja e por isso, é de extrema importância o monitoramento da sua concentração, tanto no solo quanto nas plantas. Neste sentido, o objetivo deste trabalho foi avaliar a variabilidade da concentração foliar de potássio na cultura da soja por meio de mapas de diagnóstico. Foram realizadas coletas georreferenciadas e avaliações foliares da concentração de K em diferentes estádios fenológicos da cultura da soja em dois talhões agrícolas pertencentes ao Colégio Politécnico da Universidade Federal de Santa Maria (UFSM), na cidade de Santa Maria - RS. Ao longo do período de avaliação, foi possível visualizar a variação espacial e temporal dos níveis de potássio nas folhas de soja em ambos os talhões avaliados, além de também serem observados os efeitos da aplicação potássica de cobertura nos talhões. Os níveis de potássio nas folhas da cultura da soja são variáveis ao longo do ciclo de desenvolvimento, e a estratégia de análise foliar de potássio utilizada, aliada à criação de mapas de diagnóstico, permite a identificação de possível deficiência do nutriente, tanto em nível temporal quanto em nível espacial, de forma rápida.

PALAVRAS-CHAVE: Variabilidade do solo; nutrição de plantas; análise foliar

ABSTRACT

In the use of tools available in Precision Agriculture, one of the themes is the development of maps that represent the reality of a particular field. Potassium (K) is the second most exported nutrient by soybean crops, making it extremely important to monitor its concentration, both in the soil and in the plants. Therefore, the objective of this study was to evaluate the variability of potassium foliar concentration in soybean crops through diagnostic maps. Georeferenced collections and foliar evaluations of K concentration at different phenological stages of soybean cultivation were conducted in two agricultural plots belonging to the Polytechnic College of the Federal University of Santa Maria (UFSM), in the city of Santa Maria - RS. Throughout the evaluation period, it was possible to visualize the spatial and temporal variation of potassium levels in soybean leaves in both evaluated plots, as well as to observe the effects of potassium cover application in the plots. Potassium levels in soybean leaves vary throughout the development cycle, and the potassium foliar analysis strategy used, combined with the creation of diagnostic maps, allows the identification of possible nutrient deficiencies, both temporally and spatially, quickly.

KEYWORDS: ;

INTRODUÇÃO

O potássio (K) é importante fisiologicamente para as plantas pela função de promover a tolerância à estresses, como a seca, o frio, a alta luminosidade e o ataque de pragas e doenças. Além disso, é também essencial para as principais funcionalidades das plantas, incluindo a ativação enzimática, a formação de proteínas e a fotossíntese (IPI, 2013). A cultura da soja demanda de aproximadamente 48 kg ha^{-1} de K_2O por tonelada de grãos produzida e este é considerado o terceiro nutriente mais translocado dentro da planta, perdendo apenas para o fósforo e nitrogênio (EMBRAPA, 2018). O nutriente é absorvido pelas culturas via solo e com o passar do ciclo de desenvolvimento das plantas, vai apresentando tendência de redução na concentração. Com isso, quando a alta exportação de potássio não é reposta nas quantidades adequadas, pode ocorrer a redução do nutriente no solo e posteriormente, a redução da produtividade das culturas (EMBRAPA, 2019). Desta forma, o fornecimento adequado do potássio promove maior rendimento de grãos devido ao maior número de vagens por planta, porcentagem de vagens com grãos e aumento da nodulação (TRIGOLO et al., 2015; MANTOVANI et al., 2017).

A Agricultura de Precisão (AP) é um sistema de gerenciamento agrícola que está baseado na variação espacial de propriedades do solo e das plantas pertencentes a um talhão agrícola, e visa à otimização do lucro, a sustentabilidade e a proteção do ambiente. A AP tem várias formas de abordagem, mas o seu objetivo é sempre utilizar estratégias para diminuir a variabilidade das lavouras. As práticas da AP podem ser desenvolvidas em diferentes níveis de complexidade e com diferentes objetivos (VIANA et. al, 2009).

OBJETIVOS

O objetivo deste trabalho foi avaliar a variabilidade da concentração foliar de potássio na cultura da soja por meio de mapas de diagnóstico.

MATERIAL E MÉTODOS

O estudo foi conduzido em dois talhões agrícolas localizados na área didática experimental do Colégio Politécnico da Universidade Federal de Santa Maria (UFSM), em Santa Maria - RS. Os talhões estão situados nas coordenadas geográficas Latitude 29º72'37" Sul e Longitude de 53º74'97" Oeste e altitude de, aproximadamente, 100 metros. O clima da região é o Cfa, subtropical úmido e com verões quentes, segundo a classificação de Köppen. O solo da região é classificado como Argissolo Bruno-Acinzentado (SANTOS et al., 2018).

Os talhões agrícolas delimitados recebem a denominação "Barragem" e "Carrapicho" (Figura 1). O estudo foi realizado na safra 2023/2024, quando ambos os talhões estavam ocupados com a cultura da soja, sendo o talhão Barragem com o sistema plantio direto e o talhão Carrapicho com a soja em sistema sulco-camalhão, em que é feito o prévio preparo do solo. O talhão Barragem possui área de 3,29 ha e nele foi gerado um grid de quatro pontos por hectare. Já o talhão Carrapicho possui área de 4,21 ha e foi avaliado com grid de dois pontos por hectare. [rvw1] [U2] Considerou-se estes grids de amostragem para cada talhão devido à capacidade de processamento de amostras coletadas para as avaliações foliares. Para o trabalho, foram consideradas 6 coletas foliares em diferentes estágios fenológicos da cultura da soja.

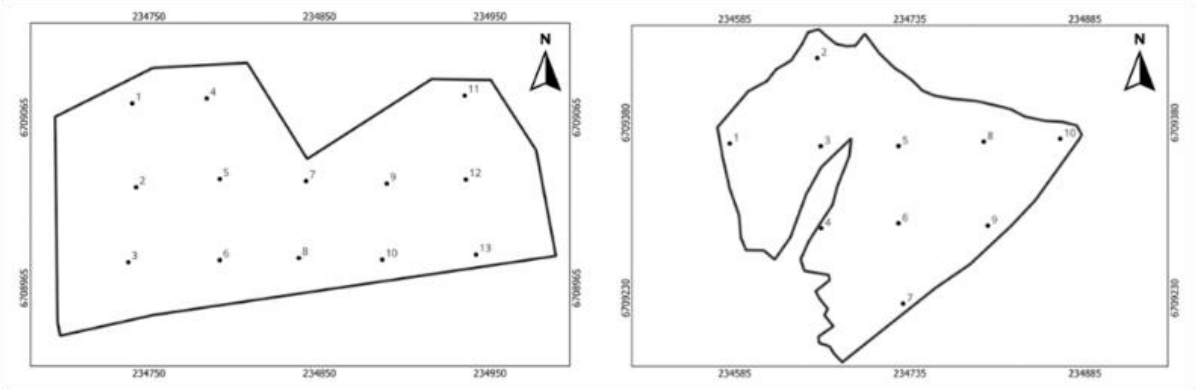


FIGURA 1. Delimitação dos talhões Barragem (esquerda) e Carrapicho (direita).

O método de análise foliar utilizado para este trabalho foi o uso de leitor portátil de íons Horiba, modelo LAQUAtwin, e o aplicativo Zeit K+. Este conjunto de equipamentos foi disponibilizado pela empresa Zeit e possibilita o diagnóstico imediato dos níveis de potássio, classificando-os em "deficiente", "fome oculta" ou "adequado".

Para realização das análises, foram realizadas coletas georreferenciadas de trifólios expandidos e sem pecíolo, no terceiro e quarto nó a partir do ápice das plantas de soja (Figura 2 A). As coletas foliares foram realizadas nas primeiras horas da manhã, pois nesse período ocorrem temperaturas amenas. O intervalo entre coletas foi de 7 a 10 dias e após coletadas, as folhas foram mantidas sob refrigeração sempre que necessário, para que não ocorresse a perda de umidade. No laboratório, a primeira etapa consistiu na calibração do sensor de íons de potássio, a qual é realizada com o uso de soluções padrões de 150 e 2000 ppm de K (Figura 2 B). Posteriormente, os folíolos foram pesados (Figura 2 C) e macerados manualmente com o uso de macerador tipo "pilão" (Figura 2 D) e água no volume de 15 ml para cada 1g de folíolo. Posteriormente, foi feita a filtragem da solução com o uso do suporte e filtro de café (Figuras 2 E e 2 F). Com isso, realizou-se a leitura do potássio foliar com o leitor de íons (Figura 2 G) e obteve-se os resultados pelo aplicativo Zeit K+ (Figura 2 H). O processo de preparo e diagnóstico rápido foi realizado sempre na mesma data das coletas foliares.

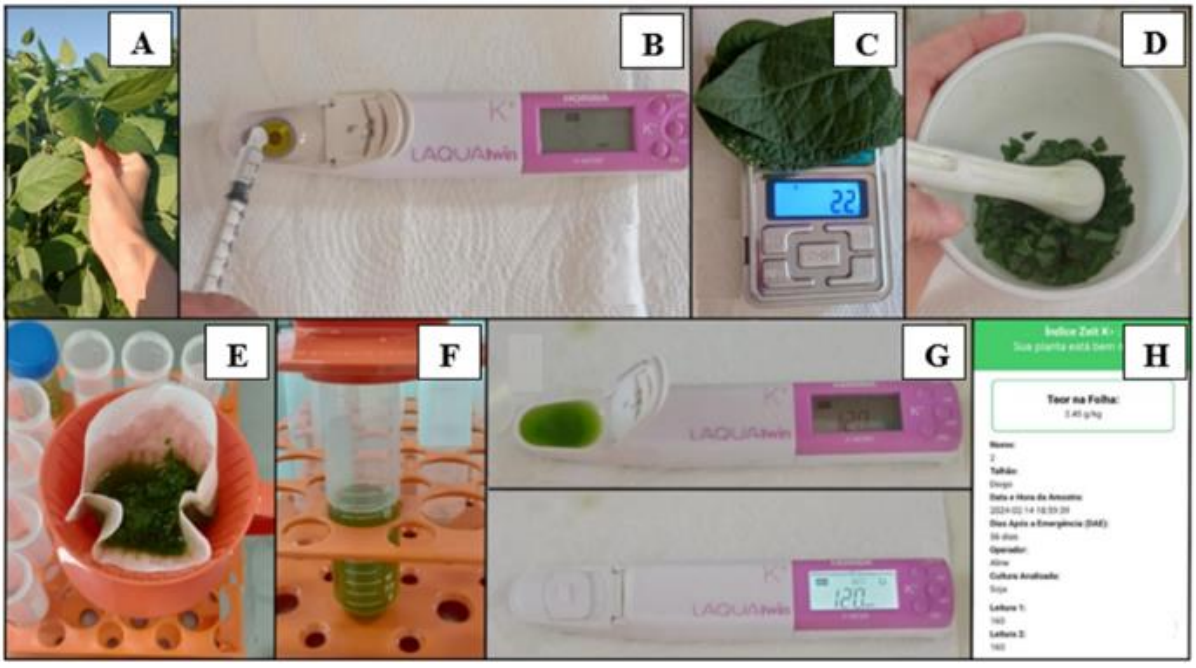


FIGURA 2. Coleta dos trifólios (A), calibração do sensor (B), pesagem das folhas (C), maceração das folhas (D), filtragem da solução (E), solução (F), triplicata das amostras e leitura em ppm (G) e resultado da avaliação via aplicativo (H).

Após a realização das análises e a obtenção dos resultados, os dados de cada ponto georreferenciado foram organizados em planilhas e utilizados para a realização dos mapas de diagnóstico. Os dados foram interpolados com o uso do software livre QGIS, pelo método IDW (inverse distance weighted - inverso das distâncias ponderadas) e com o interpolador linear entre as classes, de forma a representar melhor a variabilidade espacial e temporal dos talhões. Adotou-se o diagnóstico de potássio foliar em tons de vermelho para os pontos com deficiência, tons de cor amarela/laranja para aqueles com fome oculta e em verde para níveis adequados.

Durante o período de avaliação foliar houve manejo das áreas com aplicação a taxa fixa de cloreto de potássio (KCl) na dose de 200 kg/ha na data de 29 de janeiro de 2024 e, após esta data, foram realizadas outras avaliações foliares.

RESULTADOS E DISCUSSÃO

Durante o período de avaliação, verificou-se a ocorrência de variação espacial e temporal na concentração de potássio nas folhas de soja. Na Figura 3, são apresentados os mapas de variabilidade espacial dos níveis de potássio nas folhas de soja do talhão Barragem durante o período de avaliação. Neste cenário, observa-se que nas datas de 23 e 29 de janeiro de 2024, a maior parte do talhão foi classificada como "fome oculta" e, na data de 06 de fevereiro, os níveis regrediram para a classificação "deficiente". A próxima avaliação foi realizada na data de 15 de fevereiro de 2024, e nela foi verificado que os níveis de potássio foram classificados como "adequado" na maior parte do talhão. Após esta avaliação verificou-se que os níveis de potássio nas folhas regrediram até 11 de março de 2024, retornando para a classificação "fome oculta".

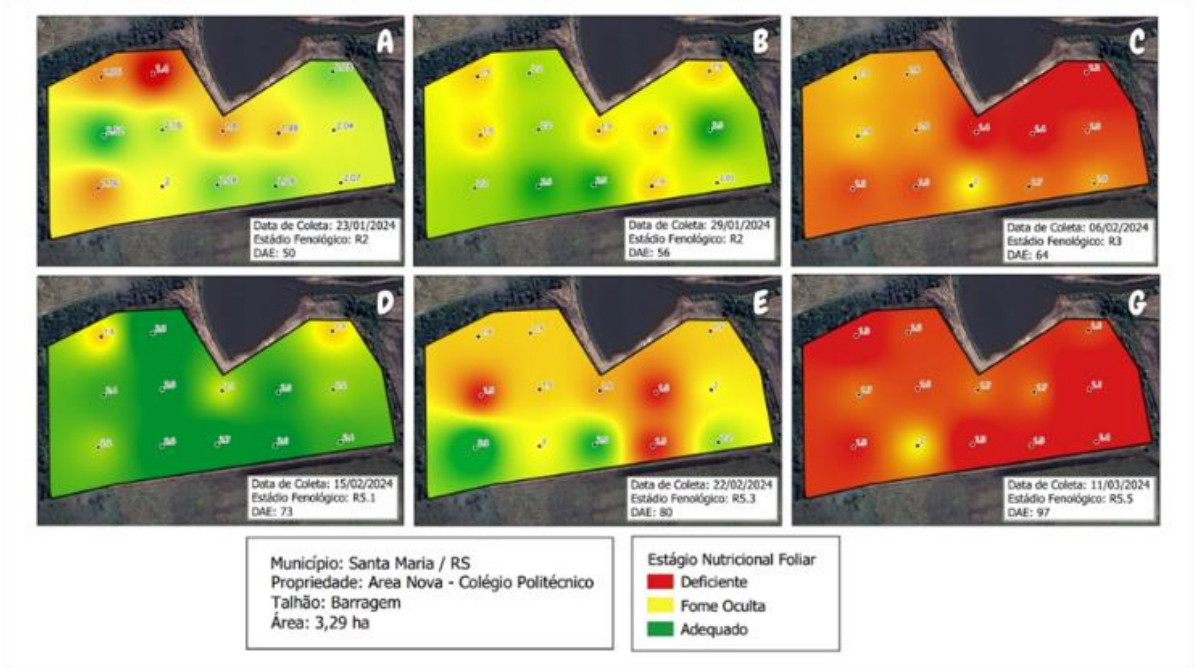


FIGURA 3. Variabilidade espacial e temporal de teores de potássio nas folhas de soja no talhão Barragem.

Na Figura 4 é apresentada a relação entre a variação temporal dos níveis de potássio nas folhas de soja por ponto de coleta, a data de aplicação de KCl em cobertura e a precipitação diária ocorrida ao longo do período avaliado, no talhão Barragem. Neste caso, é possível observar que o aumento nos

níveis de potássio ocorrido entre as datas de 6 e 15 de fevereiro de 2024 possivelmente está associado à aplicação de KCl em cobertura, realizada em 29 de janeiro de 2024. O tempo decorrido entre a aplicação do KCl e a identificação do aumento do teor de potássio foliar possivelmente está associado à ocorrência de precipitação na data de 3 de fevereiro de 2024, a qual favoreceu o transporte do KCl aplicado para a solução do solo e a consequente absorção do nutriente pelas plantas. Já a tendência de redução dos teores de KCl das datas de 15 de fevereiro a 11 de março de 2024 possivelmente está associada à translocação do nutriente para os grãos da cultura da soja, tendo em vista que o potássio é muito móvel e a sua translocação é contínua durante todo o ciclo vital da planta (CORDEIRO, 1977).

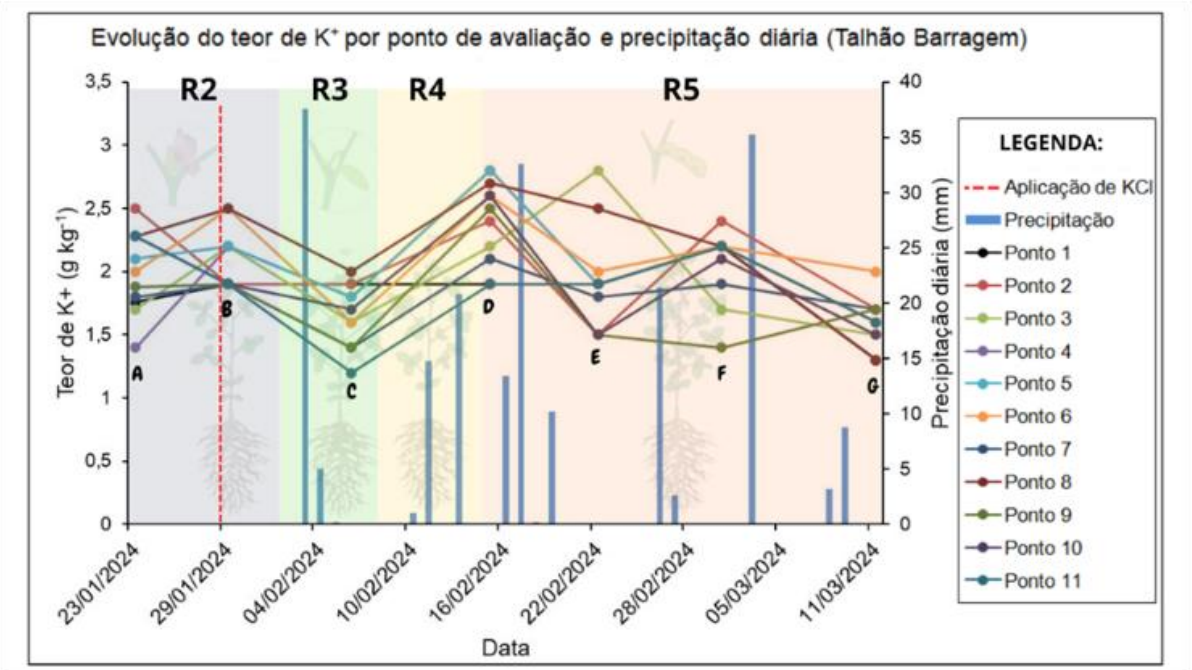


FIGURA 4. Comportamento dos teores de K foliar em relação à adubação potássica complementar via solo e precipitação diária.

Na Figura 5 são apresentados os mapas de variabilidade espacial dos níveis de potássio nas folhas de soja do talhão Carrapicho durante o período de avaliação. Neste cenário, é possível observar que os níveis de potássio nas folhas de soja estavam classificados como "Adequado" na maior parte do talhão na data de 01 de fevereiro e regrediu para a classificação "Deficiente" na data de 11 de fevereiro. A partir de 19 de fevereiro, houve aumento nos teores de potássio nas folhas na maior parte do talhão, até a data de 27 de fevereiro. Em 04 de março, houve maior variabilidade nos teores ao longo do talhão, estando aproximadamente a metade classificado como "Adequado" e a outra metade classificado como "Fome Oculta". Da data de 04 a 12 de março, os teores reduziram, de forma que a maior parte do talhão apresentou níveis de potássio classificados como "Deficiente".

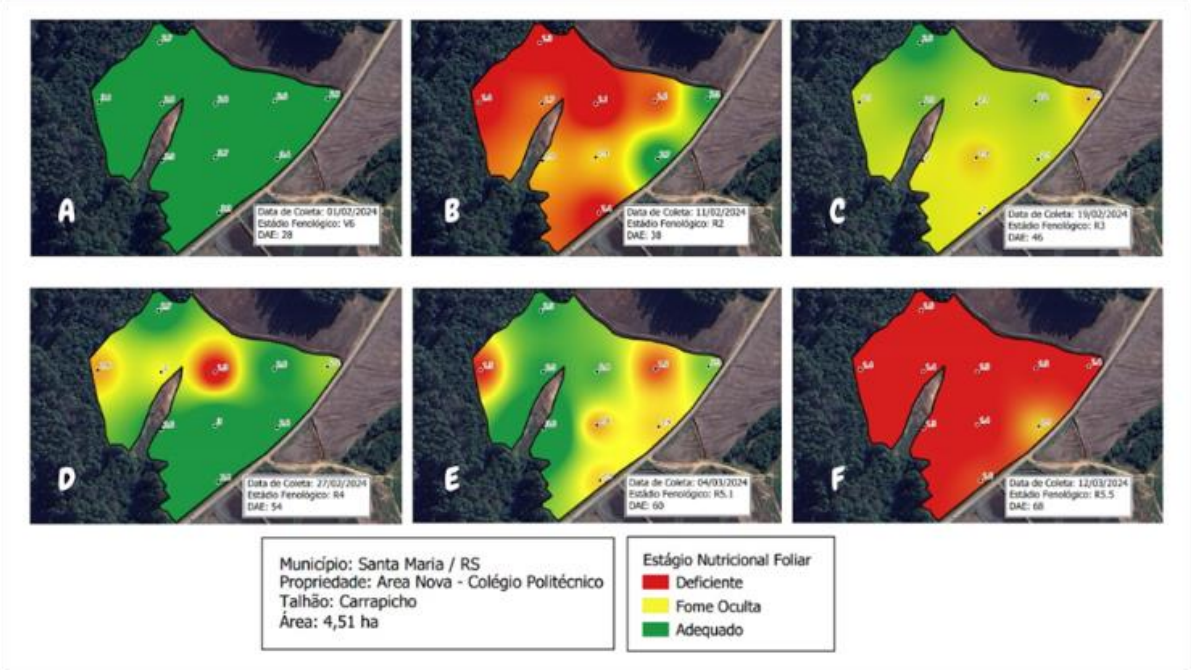


FIGURA 5. Variabilidade espacial e temporal de teores de potássio nas folhas de soja no talhão Carrapicho.

Na Figura 6 é apresentada a relação entre a variação temporal dos níveis de potássio nas folhas de soja por ponto de coleta e a precipitação diária ocorrida ao longo do período avaliado, no talhão carrapicho. Neste caso, observa-se que houve redução dos teores de potássio nas folhas de soja da data de 01 de fevereiro. Posteriormente, a partir da data de 19 de fevereiro houve uma tendência dos teores permanecerem constantes até a data de 04 de março e após isso, diminuíram novamente. Neste talhão, também houve a aplicação de KCl na data de 29 de janeiro, no entanto, a recuperação dos níveis de potássio observados nas folhas de soja foi mais lenta quando comparado ao que ocorreu no talhão barragem, embora as condições de precipitação sejam as mesmas, o que pode estar associado às variações nas características do solo entre os dois talhões, incluindo o tipo de preparo de solo utilizado.

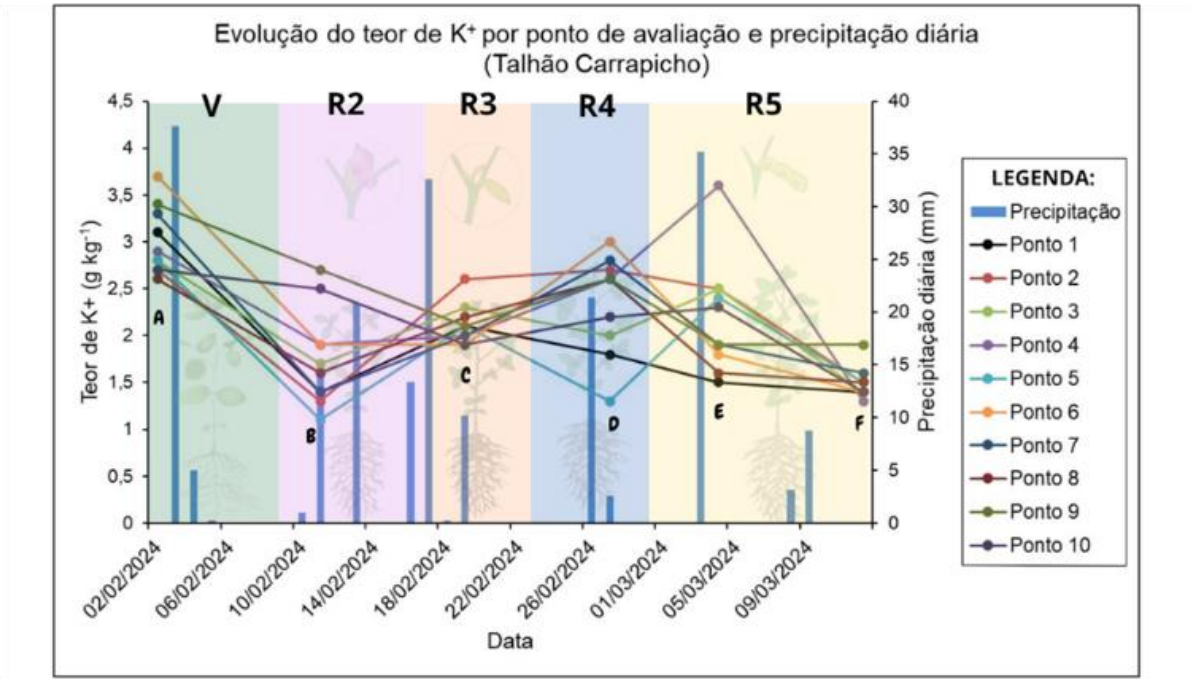


FIGURA 6. Comportamento dos teores de K foliar em relação à adubação potássica complementar via solo e precipitação diária.

CONCLUSÃO

A concentração foliar de potássio na cultura da soja é variável nos talhões agrícolas avaliados, e essa variação ocorre tanto em nível espacial quanto em nível temporal. Os métodos de avaliação da concentração de potássio nas folhas, aliados à geração de mapas de diagnóstico, permitem a identificação rápida de possíveis regiões dos talhões agrícolas que estão com deficiência do nutriente, o que se torna importante para manter os níveis de potássio adequados para a cultura durante todo o ciclo de desenvolvimento.

AGRADECIMENTOS

Ao Colégio Politécnico da UFSM e ao Projeto Advanced Farm 360, pela oportunidade de desenvolvimento do estudo dentro da instituição e às empresas Zeit e Farm 360, por possibilitarem as avaliações e criação dos mapas de diagnóstico apresentados.

REFERÊNCIAS

CORDEIRO, D. S. **Efeitos da adubação NPK na absorção, translocação e extração de nutrientes pela soj**a. Tese (Doutor em Solos e Nutrição de Plantas). Escola Superior de Agricultura "Luiz de Queiroz", da Universidade de São Paulo. Disponível em: <https://www.teses.usp.br/teses/disponiveis/11/0/tde-20240301-143734/publico/728224.pdf>. Acesso em: 25 mar. 2024. 1977.

EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária. **Teste rápido para determinação da concentração foliar de potássio (K) em condições de campo na cultura da soja**. Embrapa Soja. 2019.

EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária. **Potássio: cuidados para a manutenção do equilíbrio nutricional da soja**. Embrapa Soja. 2018.

IPI - Instituto Internacional do Potássio. **Potássio um Nutriente Essencial para a Vida**, 2013. p. 3

MANTOVANI, A.; RIBEIRO, F. J.; VEIGA, M.; ZILIO, M.; FELICIO, T. P. **Métodos de aplicação de potássio na soja em nitossolo vermelho**. Unoesc & Ciência. v.8, n.2, p. 169-176, 2017.

SANTOS, H. G. et al. **Sistema Brasileiro de Classificação de solos.** Brasília, Embrapa Solos. 356p. 2018.

TRIGOLO, A. L. M.; QUAREZEMIN, M. A. K.; GERMANO, M. G.; CASTRO, C.; OLIVEIRA JUNIOR, A. **Contribuição do potássio não trocável para a produtividade de soja e milho safrinha**. EMBRAPA. p.35-43, 2015.

VIANA, A. A. N.; FILHO, J. C. R.; MARZALL, K; HOLANDA, M. A. F.; JÚNIOR, R. C. **Agricultura de Precisão - Boletim Técnico**. Ministério da Agricultura, Pecuária e Abastecimento. p.5. 2009.

ANÁLISE DA VARIABILIDADE ESPACIAL E TEMPORAL DE ATRIBUTOS QUÍMICOS DO SOLO EM ÁREA DE PRODUÇÃO AGRÍCOLA DO COLÉGIO POLITÉCNICO DA UFSM

André Müllich [1]; Luiz Felipe Silveira Pavão [1]; Luciano Zucuni Pes [2]; Ivan Carlos Maldaner [2]; Marcelo Silveira de Farias [2]

[1]Bolsista. Av. Roraima nº 1000 Cidade Universitária Bairro - Camobi, Santa Maria - RS, 97105-900. Universidade Federal de Santa Maria; [2]Docente. Av. Roraima nº 1000 Cidade Universitária Bairro - Camobi, Santa Maria - RS, 97105-900. Colégio Politécnico da Universidade Federal de Santa Maria

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Na maior parte dos sistemas de produção, há uma oscilação na variabilidade de atributos químicos do solo, podendo ser explicada pela diferença da classificação dos solos dentro do talhão, texturas e interações entre os atributos. Com a adesão da Agricultura de Precisão, é possível identificar essa variabilidade através da criação de mapas de fertilidade, que podem auxiliar na tomada de decisão para a realização do manejo dos talhões agrícolas. Diante disso, o presente estudo objetivou realizar uma análise temporal da evolução da fertilidade do solo de macronutrientes como o fósforo (P) e potássio (K), junto à saturação por bases (V) e o potencial hidrogeniônico (pH H2O), nos anos 2012, 2017 e 2020 através do uso de mapas de fertilidade de três talhões agrícolas. Os talhões agrícolas avaliados estão localizados na Área Nova do Colégio Politécnico da Universidade Federal de Santa Maria, no município de Santa Maria - RS. Houve variabilidade nos atributos químicos nos talhões e aumento dos teores de P, K, e pH no ano de 2020, quando comparado à 2012 e 2017, com exceção da saturação por bases (V%). Esta prática de monitoramento de diagnóstico da variabilidade das áreas e posterior correção a taxa variada demonstra ser uma ferramenta muito importante para uma agricultura mais sustentável.

PALAVRAS-CHAVE: Mapas de fertilidade; Atributos Químicos; Solo

ABSTRACT

In most production systems there is an oscillation in the variability of soil chemical attributes, which can be explained by differences in soil classification within the plot, textures, and interactions between attributes. By adhering to precision agriculture, it is possible to identify this variability through the creation of fertility maps, which should assist in the producer's decision-making regarding the management of the area. Therefore, the present study aimed to conduct a temporal analysis of soil fertility evolution regarding macronutrients such as phosphorus (P) and potassium (K), along with base saturation (V) and hydrogen potential (pH H2O), in the years 2012, 2017, and 2020 using fertility maps of three agricultural plots. The evaluated agricultural plots are located in the New Area of the Polytechnic College of the Federal University of Santa Maria, in the municipality of Santa Maria-RS. There was variability in chemical attributes in the plots, with an increase in P, K, and pH levels in 2020 compared to 2012 and 2017, except for base saturation (V%). This practice of monitoring the variability of areas and subsequently correcting them using variable-rate application demonstrates to be a very important tool for a more sustainable agriculture.

KEYWORDS: ;;

INTRODUÇÃO

Na agricultura, há diversos fatores que influenciam no desenvolvimento das culturas, reduzindo a produtividade e elevando os custos de produção. Dentre esses fatores, destaca-se a fertilidade do solo, sendo os fertilizantes um dos insumos mais importantes na agricultura moderna (TISDALE et al., 1985). O Brasil é um dos maiores consumidores de fertilizantes no mundo, dado que nas últimas décadas o consumo tem crescido em média 6% ao ano (ANDA, 2014). No entanto, a eficiência na utilização desses insumos é baixa, sendo menos de 50% para o nitrogênio, menos de 100% para o fósforo e aproximadamente 40% para o potássio (BALIGAR et al., 2001). Essa baixa eficiência pode ser explicada devido à ausência de informações detalhadas da área, junto da utilização de formulações de nutrientes e quantidades fixas, que com o passar dos anos, podem favorecer um desbalanço no fornecimento dos nutrientes pelas adubações de forma sub ou superdimensionadas (BERNARDI et al., 2017). Dessa forma, em muitos casos os cálculos de correção do solo e adubação são baseados em valores médios, a partir da interpretação de uma única análise de solo por gleba, que é retirada de forma convencional. Assim é recomendado a aplicação uniforme de uma única dose média de fertilizantes em toda a extensão do campo, o que pode gerar perdas econômicas ao produtor, podendo causar também danos ambientais (SPAROVEK; SCHNUG, 2001).

Atualmente, torna-se cada vez mais popular a criação própria de mapas de fertilidade do solo e para isto, deve ser realizada a amostragem de solo no talhão, a fim de estabelecer a qualidade do solo de maneira precisa (MAPA, 2009). A definição de zonas de manejo dentro da área ocorre através da sua divisão em subáreas, esse manejo mostra-se eficiente para definir a dinâmica da lavoura e consequentemente aplicação de insumos de forma localizada (LUCHIARI et al., 2001). Uma das tecnologias da agricultura de precisão mais utilizadas por produtores é o mapeamento das propriedades do solo, através de amostragens georreferenciadas para a aplicação de corretivos e fertilizantes em taxas variáveis (BERNARDI, INAMASU et al.,2014).

O presente estudo objetivou realizar uma análise temporal da evolução da fertilidade do solo de macronutrientes como o fósforo (P) e potássio (K), junto à saturação por bases (V%) e o potencial hidrogeniônico (pH H_2O) por meio de mapas de fertilidade do solo.

OBJETIVOS

O presente estudo objetivou realizar uma análise temporal da evolução da fertilidade do solo de macronutrientes como o fósforo (P) e potássio (K), junto à saturação por bases (V%) e o potencial hidrogeniônico (pH H2O), nos anos 2012, 2017 e 2020 através do uso de mapas de fertilidade dos talhões Diogo, Erva-mate e Taquareira, localizados na Área Nova Colégio Politécnico da Universidade Federal de Santa Maria, em Santa Maria - RS. A hipótese desse trabalho é que os teores dos macronutrientes, da saturação por bases, e do potencial hidrogeniônico (pH H2O) aumentaram ao longo dos anos.

MATERIAL E MÉTODOS

O estudo foi realizado na área didático experimental denominada "Área Nova", pertencente ao Colégio Politécnico da Universidade Federal de Santa Maria, nos talhões denominados "Diogo", "Erva-Mate" e "Taquareira" (Figura 1), com área de 3,64, 13,13 e 12,42 ha, respectivamente, e altitude média de 103 metros, cujas coordenadas geográficas são: Latitude 29°43'49.75" S e Longitude 53°45'28.05" O. De acordo com a classificação de Köppen, o clima da região é do tipo Cfa - temperado chuvoso e quente, sem estação seca, úmido o ano todo, com temperatura entre 3 e 18ºC no inverno e verão com média superior a 22ºC.

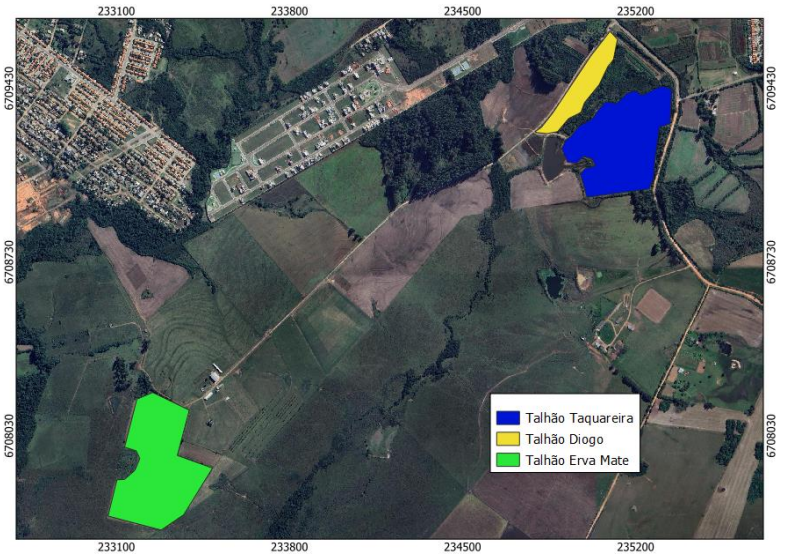


FIGURA 1. Localização da Área Nova do Colégio Politécnico da UFSM.

Na Agricultura de Precisão, a amostragem de solo georreferenciada é uma das ferramentas mais utilizadas por produtores, pois através da divisão da lavoura em pequenos talhões (grids), é possível identificar a variabilidade dos fatores de fertilidade na área. A determinação dos pontos na área de cultivo é realizada através de um equipamento de GPS (Sistema de posicionamento global), que posteriormente é utilizado para a criação dos mapas. Uma decisão responsável no manejo de fertilidade do solo pode representar 30% dos custos de produção em uma lavoura, portanto, torna-se imprescindível a busca por maiores informações e detalhamentos dos índices de fertilidade dos talhões, o qual é possível alcançar através da amostragem de solo em grids. Nos talhões Diogo, Erva-Mate e Taquareira (Figura 2), realizou-se um grid amostral de 1 ponto por hectare, sendo que cada ponto foi composto de 20 sub amostras com profundidade 0-20 cm. As coletas foram realizadas com um amostrador de solo acoplado a um quadriciclo e posteriormente encaminhadas para o laboratório de análise de solos da UFSM.

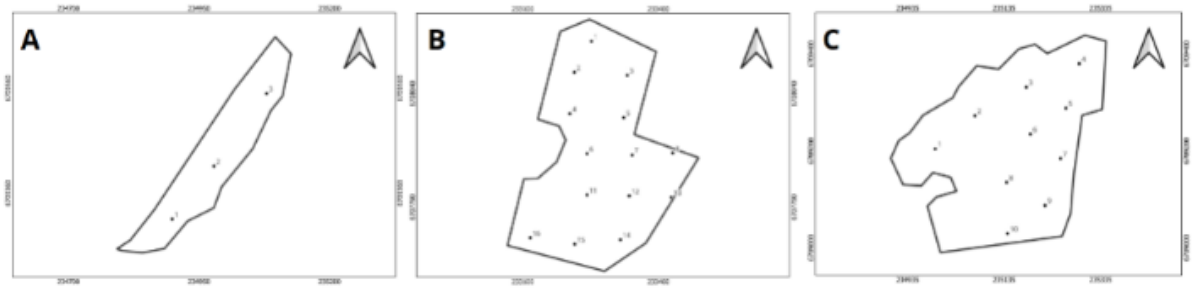


FIGURA 2. Grid amostral de 1 ponto por hectare dos talhões avaliados na série histórica. Talhão Diogo (A), talhão Erva-Mate (B) e talhão Taquareira (C).

Para análise dos dados, foi utilizado um banco de dados coletados em três anos de amostragem (2012, 2017 e 2020) dos talhões Diogo, Erva-Mate e Taquareira, contendo as seguintes variáveis: Fósforo (P), Potássio (K), Potencial Hidrogeniônico (pH) e Saturação por bases (V%), tendo como base os Manuais de Calagem e Adubação para os Estados do Rio Grande do Sul e Santa Catarina de 2016 (SBCS, 2016). O método Mehlich - 1 foi adotado para a extração de P e K pelo laboratório de análise de solos da UFSM. Ambos os nutrientes se encaixam no Grupo 2, para culturas de grãos com nível considerado exigente à disponibilidade de nutrientes. As análises de solo apresentaram classe 4 de teor de argila, e CTC pH7 de 15,1 a 30,0 para as interpretações de fósforo (P) e potássio (K), respectivamente.

A metodologia para geração dos mapas foi pelo Software QGIS, utilizando o interpolador IDW. Este é um método de estimação geoestatística que leva em consideração as características espaciais da autocorrelação de variáveis regionalizadas. É necessário que haja uma certa continuidade espacial, o que permite usar os dados obtidos por amostragem de certos pontos para estimar os valores dos pontos em sua volta.

Para a definição da disponibilidade de fósforo conforme a classe de teor de argila do solo, segundo o Manual de Calagem e Adubação para os Estados do Rio Grande do Sul e Santa Catarina de 2016, teores em mg P/dm³ menores que 10 pertencem a classe de disponibilidade muito baixo; 10 a 20, baixo; 20 a 30, médio; 30 a 60, alto; e maior que 60, muito alto.

Para a definição da disponibilidade de potássio conforme a CTC pH7 do solo, segundo o Manual de Calagem e Adubação para os Estados do Rio Grande do Sul e Santa Catarina, teores em mg K/dm³ menores que 40 pertencem a classe de disponibilidade muito baixo; 40 a 80, baixo; 80 a 120, médio; 120 a 240, alto; e maior que 240, muito alto. Para a definição dos níveis de pH em água aceitáveis no solo, levou-se em consideração que o sistema de rotação de culturas admite pH ideal 6. Os valores de saturação por bases menores que 45 pertencem a classe de disponibilidade muito baixo; entre 45 a 64, baixo; entre 64 e 80, médio e maior que 80, alto.

RESULTADOS E DISCUSSÃO

Os mapas de fertilidade do solo apresentados na Figura 3 demonstram a variabilidade espacial dos atributos químicos, sendo representados pela diferença na coloração dentro do talhão. Através dos mapas demonstrados na Figura 3 e gráficos da Figura 4, percebe-se uma evolução significativa na disponibilidade do elemento fósforo ao decorrer dos anos, o que possivelmente está associado a realização de correção do solo com calcário, o que elevou o pH e reduziu a adsorção do P pelos óxidos de ferro e alumínio, além das aplicações de adubos fosfatados a cada implantação de cultura agrícola e a reciclagem do nutriente através da rotação de culturas. Em 2012, no talhão Diogo, cerca de 67% da área estava com o nível de fósforo baixo. Em 2017, 33% do talhão estava com o nível muito baixo e em 2020 houve uma mudança abrupta, em vista de que 77% da área total do talhão ficou classificada com nível alto de fósforo.

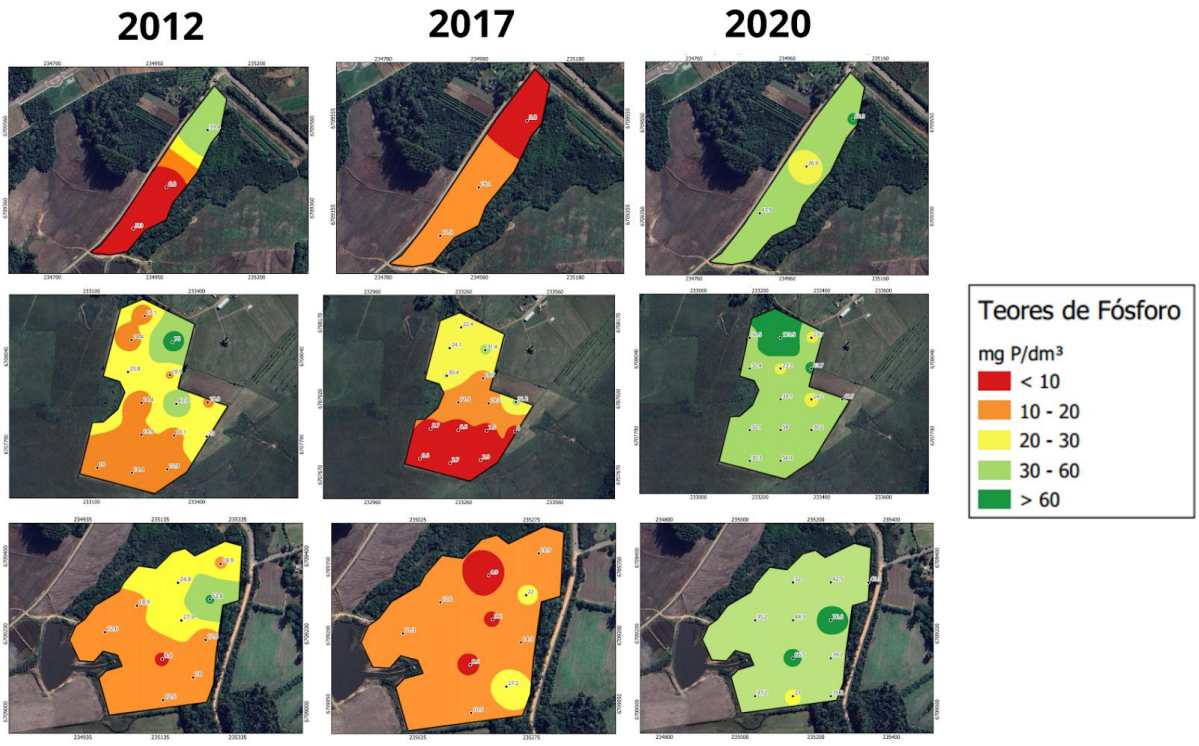


FIGURA 3. Mapas de variabilidade nos teores de fósforo (P) nos anos de 2012, 2017 e 2020.



FIGURA 4. Evolução percentual das classes dos talhões dentre os pontos coletados nos anos de 2012, 2017 e 2020.

Nas Figuras 5 e 6, são apresentados os mapas de variabilidade dos teores de potássio e evolução da classificação deste elemento nos talhões ao longo dos anos. Neste caso, no ano de 2012, o talhão Erva-Mate estava com 50% de sua área classificada com o nível de K baixo ou médio e aumentou para 92% com nível alto em 2020. Em 2017 e 2020, 100% do talhão Diogo ficou com nível de potássio alto. Dessa forma, nota-se uma evolução significativa nos teores desse elemento desde 2012 até 2020. Malavolta (1997), ressalta a importância do potássio via solo na agricultura, destacando sua função vital no desenvolvimento das plantas, na regulação osmótica, na ativação enzimática e na resistência a estresses bióticos e abióticos.

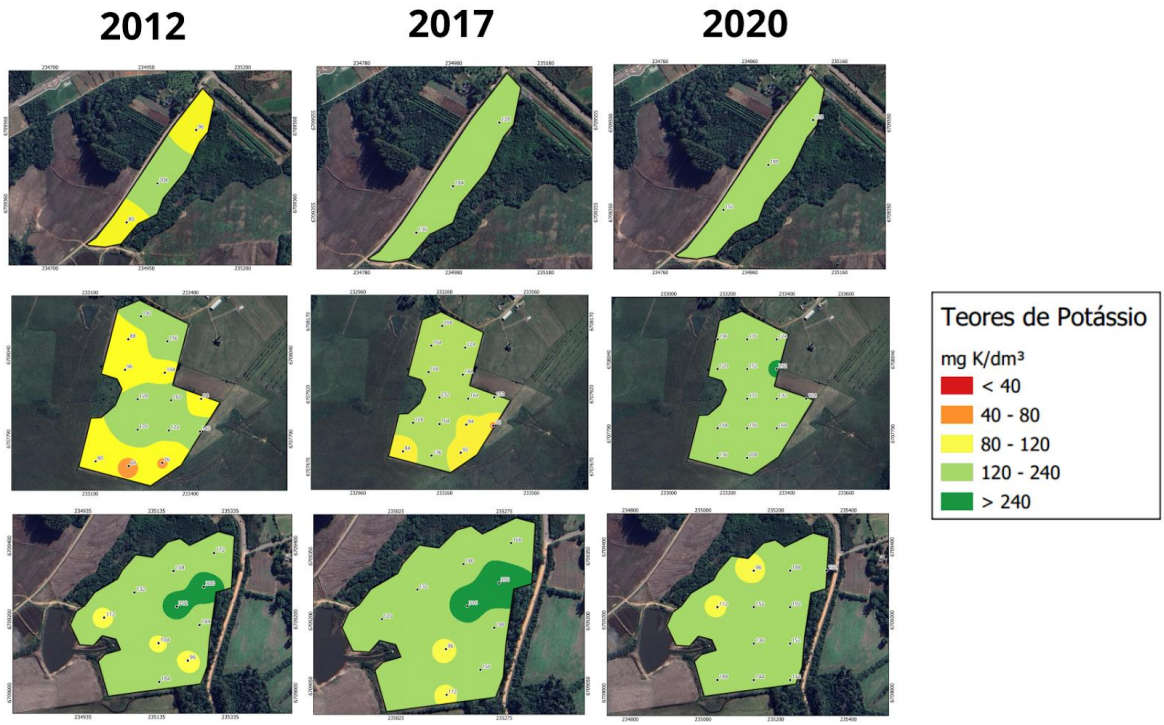


Figura 5. Mapas de variabilidade nos teores de potássio (K) nos anos de 2012, 2017 e 2020.

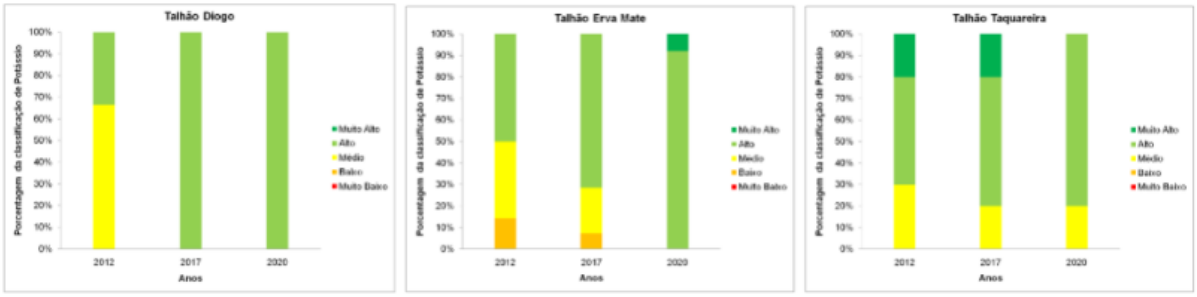


FIGURA 6. Evolução percentual das classes dos talhões dentre os pontos coletados nos anos de 2012, 2017 e 2020.

A acidez ou alcalinidade de um solo é uma das características mais importantes para a produtividade das culturas agrícolas, pois influencia diretamente a disponibilidade de nutrientes essenciais para as plantas. O pH em água é um indicador fundamental nesse contexto, afetando a solubilidade de nutrientes como P, K, Ca, Mg e micronutrientes, bem como a atividade de microrganismos do solo. Portanto, o monitoramento e o manejo adequado do pH em água são essenciais para maximizar a eficiência do uso de fertilizantes e promover uma nutrição equilibrada das plantas (Silva et al., 2019).

Nas Figuras 7 e 8, percebe-se visualmente o efeito das correções de pH do solo quando é comparado o ano de 2020 com os demais. Em 2012 e 2017, todo o talhão Diogo apresentou nível baixo de pH. No talhão Erva-Mate, aproximadamente 40% da área possuía pH igual ou inferior a 5,5 e nenhuma parte com pH maior que 6. No ano de 2017, cerca de 65% do talhão estava com o pH menor ou igual a 5,5 e 21% da área com pH maior que 6. Já em 2020, 40% da área ficou classificada com pH maior que 6. É relevante destacar que em 2012 não havia nenhuma área com o pH maior que 6, passando para 40% em 2020.

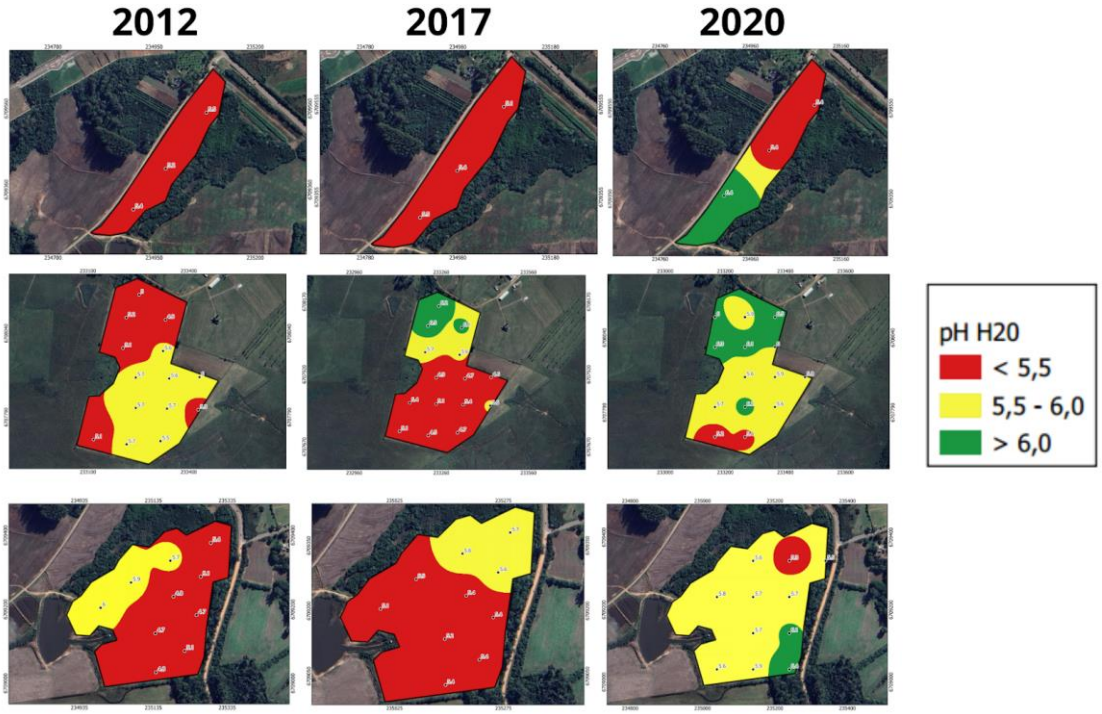


Figura 7. Mapas de variabilidade nos teores de potencial hidrogeniônico (pH H_2O) nos anos de 2012,2017 e 2020.



FIGURA 8. Evolução percentual das classes dos talhões dentre os pontos coletados nos anos de 2012, 2017 e 2020.

A saturação por bases é um parâmetro fundamental na avaliação da fertilidade do solo, pois está diretamente relacionada à disponibilidade de nutrientes para as plantas. Solos com alta saturação por bases geralmente apresentam maior capacidade de reter e fornecer nutrientes como Ca, Mg e K, influenciando diretamente no crescimento e desenvolvimento das culturas agrícolas (adaptado de Malavolta et al., 1997).

Nas Figuras 9 e 10, nota-se uma diferença significativa na variabilidade espacial dos teores de V% entre os mapas de fertilidade. No ano de 2012, há uma homogeneidade em praticamente todos os talhões, com teores acima de 64%, o que não se observa em 2017 e 2020, que demonstram maior variabilidade espacial, com elevação desses percentuais em 2017 e redução em 2020 em partes das áreas. Entretanto, em 2017, aproximadamente 21% da área estava com saturação por bases maior que 80%. Em resumo, interpreta-se que a saturação por bases não evoluiu da mesma forma que os outros parâmetros avaliados.

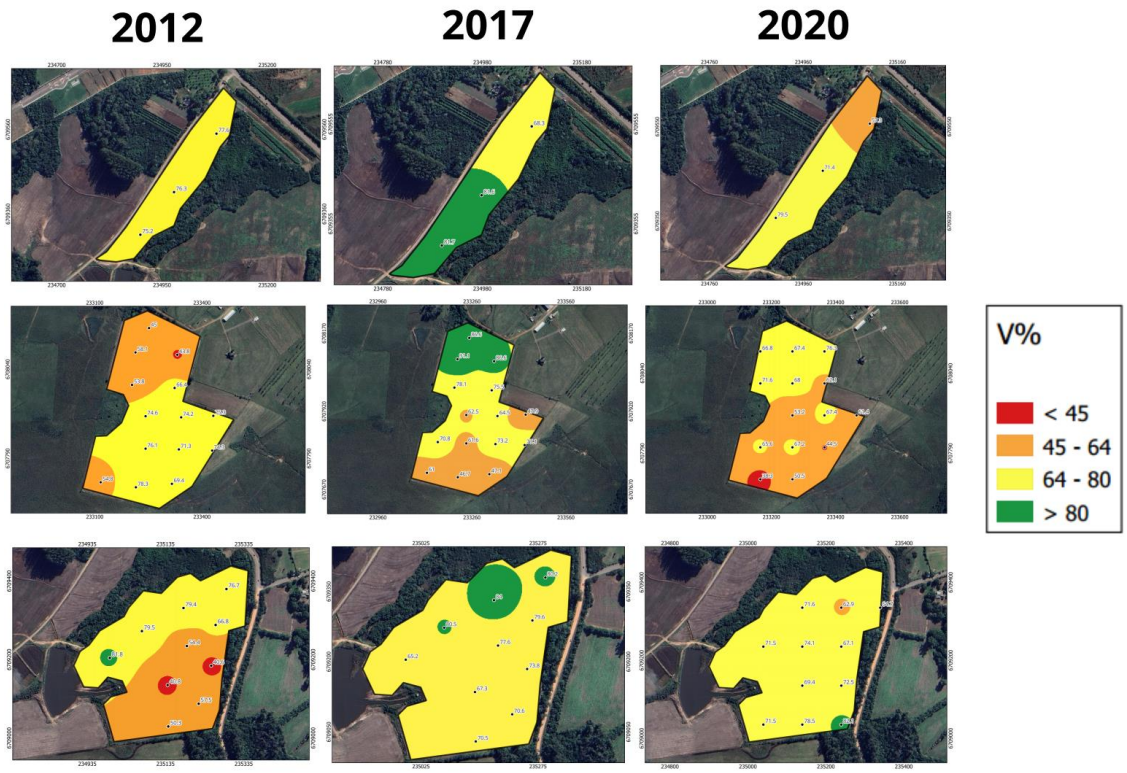


FIGURA 9. Mapas de variabilidade nos teores de saturação por bases (V%) nos anos de 2012, 2017 e 2020.

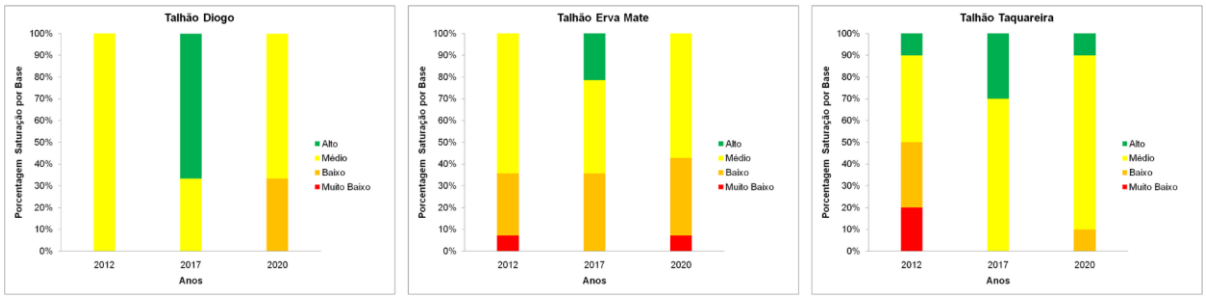


FIGURA 10. Evolução percentual das classes dos talhões dentre os pontos coletados nos anos de 2012, 2017 e 2020.

CONCLUSÃO

Conclui-se que o uso da Agricultura de Precisão, em especial com a adesão à utilização de mapas de fertilidade, permite aos produtores identificarem a variabilidade espacial dos atributos químicos do solo, de forma a otimizar na tomada de decisão para o melhor manejo a ser realizado. O presente trabalho demonstrou a variabilidade existente e como ela muda ao passar dos anos pela maneira em que o solo é manejado, o que possibilita correções e adubações a taxas variáveis, visando eficiência, rentabilidade e a sustentabilidade da produção agrícola. De modo consequente, essas ferramentas desempenham um papel crucial no avanço da Agricultura de Precisão e impulsionam a produção agrícola de forma responsável e alinhado às exigências da sociedade contemporânea.

REFERÊNCIAS

ANDA. Associação Nacional para Difusão de Adubos. Anuário estatístico do setor de fertilizantes: 2013. São Paulo, 2014. 176 p.

BALIGAR, V. C.; FAGÉRIA, N. K.; HE, Z. L. Nutrient use efficiency in plants. Communications in Soil Science and Plant Analysis, v. 37, p. 921-950, 2001.

Bernardi, Alberto C. de Campos, et al. "FERRAMENTAS de AGRICULTURA de PRECISÃO COMO AUXÍLIO AO MANEJO DA FERTILIDADE DO SOLO." Cadernos de Ciência & Tecnologia, vol. 32, no. 1/2, 8 Feb. 2017, pp. 211-227. Access 21 Sept. 2023.

Bernardi, A.C.C., Bettiol, G.M., Ferreira, R.P. *et al.* Spatial variability of soil properties and yield of a grazed alfalfa pasture in Brazil. *Precision Agric* **17**, 737-752 (2016).

BERNARDI, A. C. C.; FRAGALLE, C. V. P.; FRAGALLE, E. P.; SILVA, J. C.; INAMASU, R. Y. Estratégias de comunicação em agricultura de precisão. Perspectivas em Ciência da Informação, v. 20, p. 189-200, 2015.

Brady, Nyle. The Nature and Properties of Soils. 15th edition. (2013).

Branding, Alpina Digital, and AgroPrecision. "A Importância Do Grid de Amostragem Na Quantidade Das Informações." Agroprecision, 23 Mar. 2019, www.agroprecision.com.br/a-importancia-do-grid-de-amostragem-na-quantidade-das-informacoes/. Accessed 22 Sept. 2023.

DE QUÍMICA, CQFS-Comissão; DO SOLO, Fertilidade. Manual de calagem e adubação para os Estados de Rio Grande do Sul e de Santa Catarina. Viçosa, Sociedade Brasileira de Ciência do Solo. 376p, 2016.

LUCHIARI JR, A. et al. Strategies for establishing management zones for site specific nutrient management. In: **Proceedings of the 5th International Conference on Precision Agriculture, Bloomington, Minnesota, USA, 16-19 July, 2000**. American Society of Agronomy, 2000. p. 1-10.

MALAVOLTA, E. e VITTI, Godofredo César e OLIVEIRA, Sebastião Alberto de. Avaliação do estado nutricional das plantas: princípios e aplicações. Piracicaba: POTAFOS. Acesso em: 06 abr. 2024 , 1997.

SPAROVEK, G.; SCHNUG, E. Soil tillage and precision agriculture: A theoretical case study for soil erosion control in Brazilian sugar cane production. Soil and Tillage Research, Amster-dam, v. 61, n. 1-2, p. 47-54, 2001.

SANTI, A. L.; SEBEM, E.; GIOTTO, E.; AMADO, T. J. C. Agricultura de Precisão no Rio Grande do Sul. 01. ed. Santa Maria/RS: Triunfal Gráfica e Editora, 2016. v. 1000. 309p.

TISDALE, S. L.; NELSON, W. L.; BEATON, J. D. Soil Fertility and Fertilizers. 4th ed. New York: Macmillan Publishing Company, 1985.

PRODUTIVIDADE DE CAFÉ BENEFICIADO E A RELAÇÃO COM A MATURAÇÃO DOS FRUTOS OBTIDA A PARTIR DO USO DE IMAGENS

GUILHERME PERUZZI CÂNDIDO [1]; SANDRO MANUEL CARMELINO HURTADO [2]; ARTHUR ALVES LEMOS [1]; VITÓRIA MARIA ALVES NUNES [1]; MARIELLE RODRIGUES DUTRA [3]

[1]Graduando. Uberlândia - MG. Instituto de Ciências Agrárias; [2]Professor. Uberlândia - MG. Instituto de Ciências Agrárias; [3]Pesquisadora. Indianópolis - MG. Fazenda Mandaguari

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

O café é de ampla importância para a economia do Brasil, onde o uso de novas tecnologias direcionar estratégias visando o aumento da eficiência produtiva. O trabalho de pesquisa teve por objetivo evidenciar a importância que o momento da colheita do café tem sobre a produtividade de grãos beneficiados e a sua possível relação com a qualidade final do fruto. O local de 27 ha, encontra-se a 980 m de elevação, com a cultura de café irrigado por gotejamento. Uma malha de 50 pontos foi demarcada com uso do software Qgis, para a coleta de informações. Em cada ponto foram identificadas quatro plantas e realizadas a colheita manual e a obtenção de fotografias do material colhido. As imagens foram obtidas a partir de um celular com câmera de 50 megapixels a 1,70 m do chão. Para obtenção da produtividade os grãos foram secados até uma umidade próxima de 11,5% e beneficiados. A análise das imagens consistiu na obtenção das porcentagens dos diferentes graus de maturação encontrados no momento da colheita. Mapas de dependência espacial foram obtidos para todos os dados coletados com uso da geoestatística e Qgis. Os resultados permitiram concluir que há dependência espacial para os atributos café beneficiado e grau de maturação de frutos no momento da colheita. A relação encontrada entre estes atributos no momento da colheita pode afetar a resposta em produtividade e qualidade, sobretudo quando verificada maior presença de grãos com maturação verde.

PALAVRAS-CHAVE: Maturação de café; imagens; variabilidade espacial

ABSTRACT

Coffee has a great importance to the Brazilian economy, where the use of new technologies driving strategies aimed at increasing production efficiency. The research aimed to highlight the importance that the moment of coffee harvesting has on the productivity of processed beans and its possible relationship with the final quality of the fruit. The 27-hectare site is located at an elevation of 980 m, with drip-irrigated coffee plants. A grid of 50 points was demarcated using Qgis software to collect information. At each point, four plants were identified, manual harvesting was carried out and photographs of the harvested material were obtained. The images were obtained from a cell phone with a 50-megapixel camera at 1.70 m above the ground. To obtain productivity, the beans were dried to a moisture content of approximately 11.5% and processed. The analysis of the images consisted of obtaining the percentages of the different degrees of maturity found at the time of harvest. Spatial dependence maps were obtained for all data collected using geostatistics and Qgis. The results allowed us to conclude that there is spatial dependence for the attributes processed coffee and degree of fruit ripeness at the time of harvest. The relationship found between these attributes at the time of harvest can affect the response in productivity and quality, especially when a greater presence of green-ripened beans is verified.

KEYWORDS: Coffee maturation; images; spatial variability

INTRODUÇÃO

A cultura do café é um pilar no desenvolvimento econômico do Brasil, com cerca de 8,4 milhões de empregos (CNC, 2021), onde destaca o estado de Minas Gerais com produção próxima de 29 milhões de sacas (CONAB, 2023). Visando o aprimoramento da resposta produtiva da cultura, é importante o desenvolvimento de técnicas de manejo que permitam direcionar estratégias para a maior eficiência do sistema produtivo (LIMA *et al*., 2013), o que é viabilizado a partir do uso da Agricultura de Precisão (GEBBERS; ADAMCHUK, 2010). Entre estas técnicas pode-se mencionar o uso de imagens para identificação do ponto ideal de colheita (MEIRELES et al., 2009). O trabalho teve por objetivo evidenciar a importância do momento da colheita do café na produtividade de grãos beneficiados e a possível relação com a qualidade final do fruto.

OBJETIVOS

Evidenciar a importância que o momento da colheita do café tem sobre a produtividade de grãos beneficiados e a sua possível relação com a qualidade final do fruto.

MATERIAL E MÉTODOS

O experimento foi realizando em um talhão de 27 ha pertencente à Fazenda Mandaguari, município de Indianópolis, MG (18º59'39.51" S; 47º47'30.33" O), a 980 metros de altitude. A lavoura implantada, há dois anos com *Coffea arábica*, cultivar Topázio, em sistema de irrigação por gotejamento, apresenta espaçamento entre linhas de 3,8 m e entre plantas de 0,7m, totalizando 3.759 plantas. ha^{-1}.

Na área foi demarcada uma malha homogênea com 50 pontos amostrais, numa densidade de dois pontos por ha, a partir do uso do software Qgis. A localização dos pontos a campo foi a partir do receptor GNSS de navegação E-trex Vista 30X. Para cada ponto foram selecionadas e identificadas quatro plantas, sendo duas plantas vizinhas em duas linhas de plantio contiguas. Na seleção das plantas foram evitadas aquelas fora do padrão predominante para o local.

O processo de colheita foi manual, com auxílio de lonas alocadas na parte inferior das plantas, visando evitar perdas. Os frutos foram limpos de impurezas como folhas e galhos, homogeneizados e dispostos sobre lonas para obtenção de fotografias do material colhido. As imagens foram obtidas evitando a incidência direta do sol sobre as amostras, com uso de um celular marca Samsung®, modelo A55, com câmera principal de 50 megapixels e zoom de 1.0, a uma altura de 1,70 m do chão. Posteriormente, os grãos de café foram levados para secagem natural no terreiro em piso de cimento, até atingirem umidade próxima de 11,5%. Concluída a secagem, os grãos foram beneficiados considerando uma alíquota de 2 kg de café em coco, pesados e obtida a produtividade dos grãos limpos.

A análise das imagens foi realizada com uso do software Qgis, a partir da contagem simples de grãos contido em uma subamostra de aproximadamente 300 grãos (513.099 pixels). Foram obtidas as porcentagens de grãos correspondentes as fases de maturação verde, verde-cana, cereja, passa e seco. De posse dos dados de peso dos grãos e da análise visual dos frutos, foi realizada a análise espacial por meio da geoestatística, com auxílio do complemento Smart-Map, no ambiente Qgis.

RESULTADOS E DISCUSSÃO

Os resultados da análise descritiva permitem verificar uma média de 61,2 $sc.ha^{-1}$ de café beneficiado, valor superior à média nacional de 30 $sc.ha^{-1}$ (Tabela 1). Quando avaliado o grau de maturação no momento da colheita observa-se a maior porcentagem para o café com grãos secos (70,1%) e a menor para o tipo cereja (3,4%), com destaque para os quase 9% de café considerado como verde. A proximidade dos valores de média e mediana indicam um possível comportamento normal nos dados.

Por sua vez, os dados de coeficiente de variação (CV%) permitem evidenciar altos valores para a maioria de atributos (CV>20%), a exceção do CV registrado para os grãos colhidos como secos (10%<CV<20%) (Gomes, 1990), servindo como indicativo de presença de variabilidade espacial nos dados (Tabela 1).

Tabela 1. Análise descritiva para os dados de produtividade de café beneficiado e porcentagens de maturação do grão no momento da colheita de café.

	Mínimo	Máximo	Média	Mediana	Erro padrão	CV
Café Beneficiado (sc/ha)	33,3	132,9	61,2	50,3	3,1	35,6
Grãos Verde (%)	0,6	29,3	8,7	6,9	0,8	68,5
Grãos Verde Cana (%)	1,6	17,4	7,0	6,4	0,5	52,8
Grãos Cereja (%)	0,6	13,2	3,4	3,0	0,3	62,7
Grãos Passa (%)	3,1	29,4	10,9	9,4	0,8	49,8
Grãos Seco (%)	46,8	86,1	70,1	70,8	1,5	15,1

CV: coeficiente de variação

A análise espacial dos dados, realizada a partir da geoestatística, permitiu verificar a existência de dependência espacial para os atributos café beneficiado e grãos com maturação em verde e cereja, com semivariogramas do tipo esférico e alcances entre 90 m (cereja) e 150 m (café beneficiado). Para estes atributos foi possível a geração de mapas a partir da interpolação por krigagem (SILVA et al., 2008). Para os demais atributos foi verificado a existência de efeito pepita puro, sendo a interpolação realizada pelo inverso do quadrado da distância (IDW).

A maior produtividade de grãos beneficiados (Figura 1A) é verificada na parte sul do talhão. Para Couto *et al.,* (1999), a massa específica aparente de grãos cresce com a diminuição do teor de umidade do produto, sendo que áreas com maior porcentagem de grãos secos podem apresentar maior massa e produtividade final. Esse mesmo comportamento espacial é verificado para os mapas gerados a partir das porcentagens de grãos com maturação verde e verde cana (Figuras 1B e 1C). Por sua vez, comportamento oposto a estes pode ser evidenciado para os grãos com maturação considerado como seco (Figura 1F). Esta relação condiz com a análise de correlação, onde foi visualizada relação direta entre a produtividade de café já beneficiado e os grãos colhidos como verdes (r= 0,68) e verde cana (r= 0,68), e relação inversa com os grãos colhidos como secos (r= -0,65). A presença de correlação espacial na maturação das plantas foi descrita também por KAZAMA et al. (2020).

A partir da figura 1 é possível verificar correlação inversa (r= -0,73) entre o grão de maturação verde (Figura 1B) e seco (Figura 1F), indicando a desuniformidade para o tempo de maturação. De acordo com Souza *et al.* (2016), fatores climáticos, em especial a temperatura, afetam diretamente o somatório de graus- dia próprio a cada fase fenológica. Semelhante comportamento visual foi verificado para os mapas com grãos na maturação verde cana (Figura 1C) e cereja (Figura 1D).

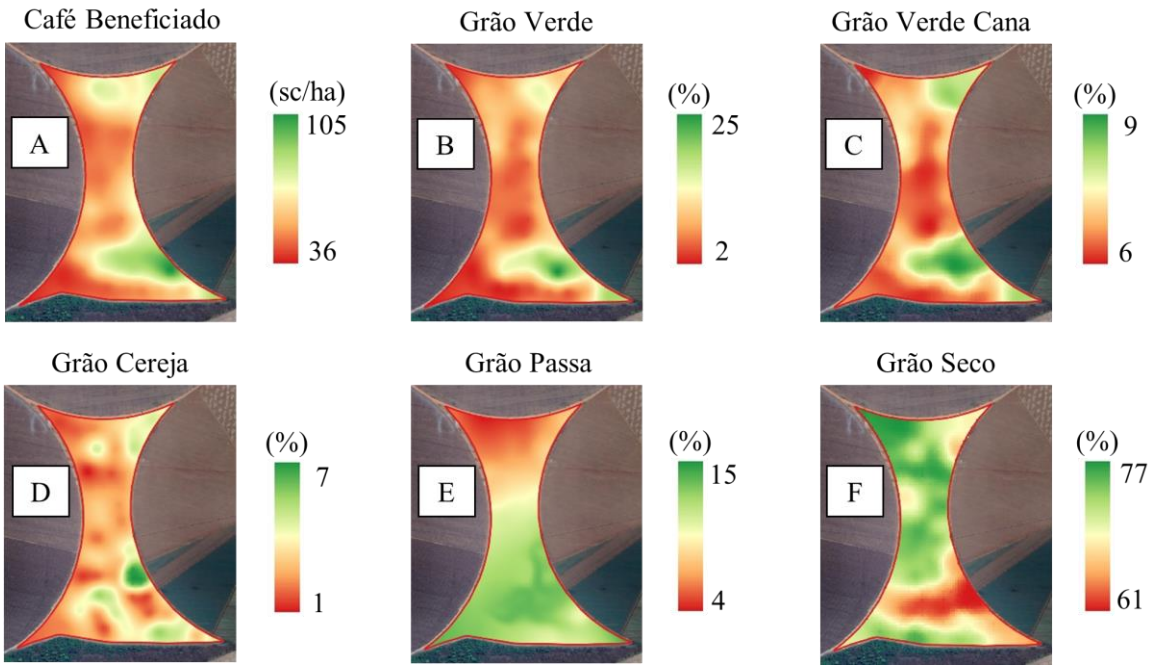


Figura 1. Análise espacial para os dados de produtividade de café beneficiado e porcentagens de maturação do grão no momento da colheita de café.

A relação encontrada entre a produtividade de grãos já beneficiados e a porcentagem de grãos com maturação verde e verde cana (Figuras 1 A, B e C), alerta para a existência de variabilidade na umidade dos grãos no processo de secagem. Embora os grãos tenham sido retirados do terreiro ao atingirem umidade próxima de 11,5%, a variação de umidade, ao parecer, foi mantida entre os diversos tipos de grãos colhidos. Esta informação alerta ainda para a elaboração de cafés especiais, onde a maior participação de grãos verdes no lote pode afetar a composição e a qualidade final da bebida. Por sua vez, o presente trabalho demonstrou ser possível especializar o grau de maturação dos grãos no momento da colheita. Esta informação é válida para a verificação do trabalho de colheita manual, ao atribuir melhores benefícios quando requerido um maior cuidado na colheita de grãos cereja, por exemplo. Finalmente, abre-se a possibilidade para a definição do melhor momento da colheita por meio do uso de imagens, podendo ser esta mais bem validada quando o fruto se encontrar ainda no pé.

CONCLUSÃO

Há dependência espacial para os atributos café beneficiado e grau de maturação de frutos no momento da colheita. A relação encontrada entre estes atributos no momento da colheita pode afetar a resposta em produtividade e qualidade, sobretudo quando verificada uma maior presença de grãos com maturação verde.

AGRADECIMENTOS

Agradecemos à Fazenda Mandaguari e ao Grupo de Estudos em Agricultura de Precisão (GeAP-UFU) pelo apoio na condução dos trabalhos.

REFERÊNCIAS

Conselho Nacional do Café - CNC. **Café do Brasil**: confira a história. Confira a história, 2021, Disponível em: https://cncafe,com,br/cafe-do-brasil-historia/. Acesso em: 18 ago 2024.

COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB. **Acompanhamento da safra brasileira de café.** Brasília, DF, v. 10, n, 4, dez. 2023.

COUTO, S. M. *et al.*, Massa específica aparente e real e porosidade de grãos de café em função do teor de umidade. **Revista Brasileira de Engenharia Agrícola e Ambiental.** v. 3, n. 1, p. 61-68, 1999. http://dx,doi,org/10,1590/1807-1929/agriambi,v3n1p61-68.

GEBBERS, R.; ADAMCHUK, V. I. Precision agriculture and food security. **Science.** Nova Iorque, v. 327, p. 828-831, fev. 2010.

GOMES, F.P. Curso de estatística experimental. 12.ed. São Paulo: Nobel, 1990. 467p.

KAZAMA, E. H., DA SILVA, R. P., DE OLIVEIRA TAVARES, T., CORREA, L. N., DE LIMA ESTEVAM, F. N., DE ARAÚJO NICOLAU, F. E., & JÚNIOR, W. M. Methodology for selective coffee harvesting in management zones of yield and maturation. Precision Agriculture, n. 0123456789, 2020. https://doi.org/10.1007/s11119-020-09751-1. Disponível em: < https://link.springer.com/article/10.1007/s11119-020-09751-1>

LIMA, J. S. S. *et al*, Variabilidade espacial de atributos químicos de um Latossolo Vermelho-Amarelo cultivado em plantio direto. **Revista Ciência Agronômica,** v. 44, n. 1, p. 16-23, 2013. http://dx,doi,org/10,1590/s1806-66902013000100003.

MEIRELES, E. J. L., CAMARGO, M. B. P. D., PEZZOPANE, J. R. M., THOMAZIELLO, R. A., FAHL, J. I., BARDIN, L., ... & FERREIRA, R. A. Fenologia do Cafeeiro: Condições Agrometeorológicas e Balanço Hídrico do Ano Agrícola 2004-2005. Embrapa-Documentos. ISSN 1678-1694. Brasilia-DF: 2009. Disponível em: < http://www.sbicafe.ufv.br:80/handle/123456789/3381>.

SILVA, F. M. *et al.* Variabilidade espacial de atributos químicos e produtividade da cultura do café em duas safras agrícolas. **Ciência e Agrotecnologia**, v. 32, n. 1, p. 231-241, 2008. http://dx,doi,org/10,1590/s1413-70542008000100034.

SOUZA, C. A. de *et al*. Componentes genéticos do desenvolvimento e maturação de frutos de Coffea canephora pierre ex a.froehner. **Coffee Science**, Lavras, v. 12, n. 3, p. 355-364, 2016.

ÍNDICE NDVI E A SUA CORRELAÇÃO COM A PRODUTIVIDADE DE CAFÉ

Múcio Fernando Rodrigues Carneiro Filho [1]; Sandro Carmelindo Hurtado [2]; Wanessa Gonçalves Siquieroli [1]; Felipe Henrique Leandro [1]; Barbara Caetano [1]
[1]Graduando. Ubelândia-MG. Universidade Federal de Uberlândia; [2]Professor. Ubelândia-MG. Universidade Federal de Uberlândia

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
A cultura do café é de importância mundial para o agronegócio o que torna necessário o aprimoramento de técnicas visando a obtenção de maiores patamares produtivos. O trabalho de pesquisa teve por objetivo correlacionar a informação do índice de vegetação NDVI com a produtividade de café em diferentes estágios do beneficiamento. O trabalho foi desenvolvido uma área de 27 ha, em Indianópolis, MG com a cultura do café arábica irrigado por gotejamento. Na área foi desenhada uma grade georreferenciada de 50 pontos amostrais (2 pontos/ha) para a coleta de dados de produtividade. Em cada ponto da grade foram colhidas 4 plantas de forma manual. Os grãos foram pesados nos diferentes estágios de beneficiamento, úmidos, secos e limpos de impurezas. A partir dos dados foi realizada análise geoestatística e mapas com auxílio do programa Qgis e do plugin Smart Map. Imagens de satélite Planet foram utilizadas para a elaboração do índice NDVI da lavoura em etapa anterior a colheita e a partir dessa informação foram obtidas correlações com os dados de produtividade de café. Os resultados permitem concluir a presença de correlação espacial para os dados de produtividade nas diferentes fases de beneficiamento. Entretanto, os dados de biomassa obtido por meio de índices de vegetação podem não corresponder a realidade produtiva, dada a bienalidade própria da cultura do café.

PALAVRAS-CHAVE: NDVI; Café; Produtividade

ABSTRACT
Coffee cultivation have a global importance for agribusiness, which makes it necessary to improve techniques in order to obtain higher levels of production. The research work aimed to correlate the information of the NDVI vegetation index with coffee productivity at different stages of processing. The work was developed in an area of ??27 ha, in Indianópolis, MG, with the Arabica coffee crop irrigated by drip irrigation. A georeferenced grid of 50 sampling points (2 points/ha) was designed in the area to collect productivity data. At each point of the grid, 4 plants were harvested manually. The beans were weighed at different stages of processing, wet, dry and clean of impurities. From the data, geostatistical analysis and maps were performed with the aid of the Qgis program and the Smart Map plugin. Planet satellite images were used to prepare the NDVI index of the crop at a stage prior to harvesting, and from this information, correlations with the coffee productivity data were obtained. The results allow us to conclude that there is a spatial correlation for productivity data in the different processing phases. However, the biomass data obtained through vegetation indices may not correspond to the productive reality, given the biennial nature of coffee cultivation.

KEYWORDS: NDVI; Coffee; Productivity

INTRODUÇÃO

A cultura do café apresenta importância mundial e nacional com produção no país próxima de 30 milhões de sacas no ano de 2024 (CONAB, 2024). É com base nessa relevância que se torna necessário o estudo e aprimoramento de técnicas visando a obtenção de maiores patamares

produtivos. Conta-se neste sentido, com as ferramentas de agricultura de precisão como importante aliada para a toma de decisões na lavoura, visando minimizar custos e potencializar as produtividades. O trabalho de pesquisa teve por objetivo correlacionar a informação do índice de vegetação NDVI com a produtividade de café em diferentes estágios do beneficiamento.

OBJETIVOS

Correlacionar a informação do índice de vegetação NDVI com a produtividade de café em diferentes estágios do beneficiamento.

MATERIAL E MÉTODOS

O trabalho foi desenvolvido em área experimental de 27 ha, pertencente à Fazenda Mandaguari, em Indianópolis, MG (-18,99; - 47,80). No talhão é cultivado há 2 anos o café arábica (Coffea arábica L.), cultivar Topázio, espaçamento de 0,7 m entre plantas e 3,8 m entre linhas, e apresenta solo tipo Latossolo Vermelho e irrigação por gotejamento. Para coleta de informações foi desenhada uma grade georreferenciada contendo 50 pontos amostrais (2 pontos/ha), com auxílio do software Qgis.

Para a coleta de dados de produtividade foram marcadas 4 plantas (2 plantas em sequência em 2 linhas vizinhas), e colhidos todos seus frutos de forma manual, em 11/07/2024. Os grãos úmidos foram pesados e levados para o terreirão para secagem, e pesados novamente após atingirem uma umidade próxima de 11,5%. A uniformidade de secagem foi garantida ao virar o material colhido de duas a três vezes no dia. Como passo posterior, as amostras foram beneficiadas com uso de maquinário elétrico. Foram separados o grão da casca e pesados os grãos beneficiados para os 50 pontos da grade amostral. A partir dos dados foi realizada análise espacial com uso da geoestatística e elaborados mapas para as diferentes fases do processamento do café (café úmido, seco e beneficiado), com auxílio do programa Qgis e do plugin Smart Map.

Imagens de satélite Planet, de 3m/pixel, foram adquiridas em data prévia a colheita e elaborado a partir dela o índice de vegetação por diferença normalizada- NDVI. A partir do índice foi extraída a informação raster (pixel) relativa a cada um dos pontos da grade amostral de 50 pontos e correlacionadas com os dados de produtividade de café.

RESULTADOS E DISCUSSÃO

A partir dos dados da análise descritiva podemos observar uma média de produtividade de 61,2 sc/ha, superior à média nacional de aproximadamente 30 sc/ha, registrada para o ano de 2024 (Tabela 1). Os dados permitem evidenciar quedas nos valores de produtividade na ordem de 30% quando terminado o processo de secagem e de mais 52% quando beneficiados os grãos, dando uma redução de peso total de 67% em relação aos grãos colhidos a campo (Tabela 1). Cabe destacar os elevados coeficientes de variação (CV>20%) registrados para todos os atributos (Gomes, 1990), denotando uma possível presença de variação espacial nos dados.

Tabela 1. Análise descritiva dos dados de produtividade de café úmido, seco e beneficiado.

Produtividade (sc/ha)	Mínimo	Máximo	Média	Mediana	Erro padrão	CV (%)
Café Úmido	79,1	326,6	184,4	157,8	10,3	39,6
Café Seco	70,5	216,9	128,0	110,4	5,4	29,6
Café Beneficiado	33,3	132,9	61,2	50,3	3,1	35,6

Quando avaliada os dados de forma espacial foi encontrada presença de correlação espacial para os dados de produtividade de café, o que permitiu a geração de mapas (Figura 1).

Dependência espacial foi registrada para a produtividade de café em trabalho descrito por Silva et al. (2007). A partir dos mapas percebe-se que a perda de umidade no processo de beneficiamento, desde grão colhido até totalmente limpo de impurezas, não alterou a distribuição espacial dos dados de produtividade (Figuras 1 A, B e C).

Quando avaliado o índice NDVI é possível observar um menor reflexo da biomassa da lavoura orientado à parte superior do talhão (Figura 1D), o que corrobora os resultados encontrados por Santos et. (2022) Esse comportamento espectral da cultura seria oposto ao observado na região superior do talhão, onde foram registradas maiores produtividades. De fato, a maior correlação entre o índice NDVI e as produtividades foi obtida quando comparada ao peso de grãos úmidos (r= -0,19). A reduzida correlação encontra explicação no comportamento bianual da cultura do café, onde num primeiro ano a cultura direciona os foto assimilados para o crescimento de ramos, e num segundo ano, para a produção de frutos. Assim sendo, a reduzida correlação foi devida a maior resposta espectral da cultura em razão do maior crescimento de ramos para este ano.

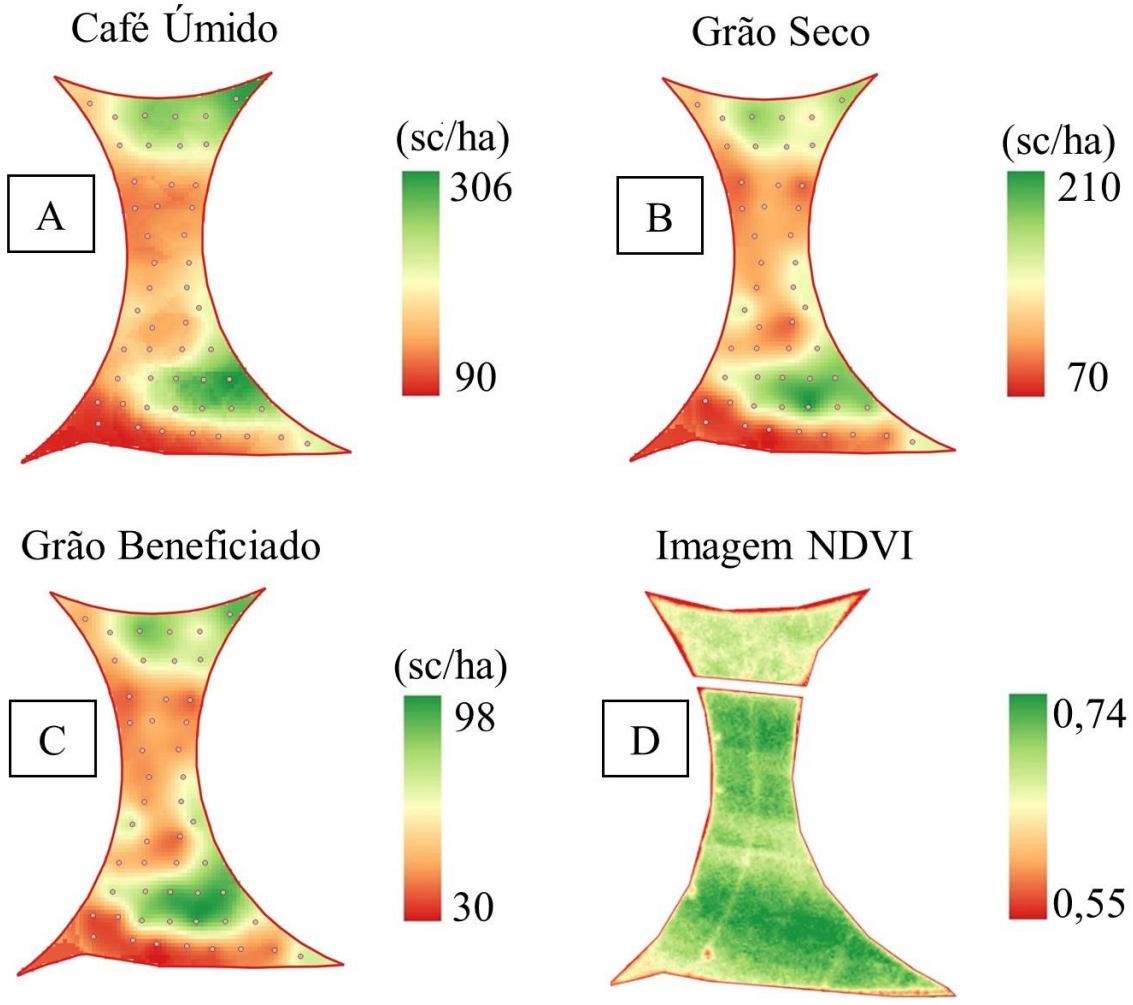


Figura 1. Análise espacial para os dados de produtividade de café úmido, seco, beneficiado e índice NDVI.

CONCLUSÃO

Há correlação espacial para os dados de produtividade nas diferentes fases de beneficiamento. Entretanto, os dados de biomassa obtido por meio de índices de vegetação podem não corresponder a realidade produtiva, dada a bienalidade própria da cultura do café.

AGRADECIMENTOS

Agradecemos à Fazenda Mandaguari e ao Grupo de Estudos em Agricultura de Precisão (GeAP-UFU) pelo apoio na condução dos trabalhos.

REFERÊNCIAS

COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB. **Acompanhamento da safra brasileira de café.** Brasília, DF. 2024.

GOMES, F.P. **Curso de estatística experimental.** 12.ed. São Paulo: Nobel, 1990. 467p.

SANTOS, S. A.; FERRAZ, G. A. S.; FIGUEIREDO, V. C.; SANTANA, L. S.; CAMPOS, B. F. D. Supervised classification and NDVI calculation from remote piloted aircraft images for coffee plantations applications. **Coffee Science**, v.16, p.1-9, 2022.

SILVA, F. M.; SOUZA, Z. M.; FIGUEIREDO, C. A. P.; MARQUES JÚNIOR, J.; MACHADO, R. V. Variabilidade espacial de atributos químicos e de produtividade na cultura do café. **Ciência Rural**, v. 37, n. 2, p. 401-407, abr. 2007.

2. Aplicação Localizada

GERAÇÃO DE MAPAS PARA APLICAÇÃO LOCALIZADA DE HERBICIDA UTILIZANDO IMAGENS AÉREAS

RONALDO SACOMANI [1]; THIAGO LIBÓRIO ROMANELLI [2]; JÉSSICA DE LUCENA MARINHO [3]
[1]Supervisor de Serviços - Jacto Next. Pompeia - SP. Jacto; [2]Docente. Piracicaba - SP. ESALQ, USP;
[3]Especialista em Agricultura de Precisão - Jacto Next. Pompeia - SP. Jacto

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
O aumento do uso de agrotóxicos na agricultura tem impactos nos custos de produção e no ambiente. Por isso, o controle eficaz das plantas daninhas é essencial para reduzir o uso de agrotóxicos. O objetivo do trabalho foi avaliar um algoritmo classificador para gerar mapas de aplicação localizada de herbicidas. Utilizando imagens georreferenciadas, ortomosaicos foram gerados como entrada para o algoritmo, que produziu os mapas. Para avaliar os mapas gerados, dados de referência em campo foram coletados, e o método da matriz de confusão de duas classes foi empregado para avaliar o desempenho do algoritmo, permitindo o cálculo dos indicadores precisão, revocação, acurácia, F-score e coeficiente de correlação linear de Pearson entre os dados de referência e o mapa gerado pelo algoritmo. Os resultados alcançaram valores médios de 0,74 para precisão, 0,95 para revocação, 0,77 para acurácia, 0,79 para F-score e 0,56 de coeficiente de correlação linear de Pearson, indicando que o algoritmo teve desempenho superior para identificar plantas daninhas com área projeta no solo maiores que 400 cm². O mapeamento das plantas daninhas constitui uma técnica eficaz e promissora para o manejo localizado, permitindo a redução do volume de herbicidas aplicados, dos custos de produção e do impacto ambiental gerado pelas pulverizações.

PALAVRAS-CHAVE: agricultura sustentável; detecção de plantas daninhas; inteligência artificial

ABSTRACT
The increased use of pesticides in agriculture has impacts on production costs and the environment. Therefore, effective weed control is essential to reduce pesticide usage. The aim of this study was to evaluate a classifier algorithm for generating localized herbicide application maps. Using georeferenced images, orthomosaics were generated as input for the algorithm, which produced the maps. Field reference data were collected to evaluate the generated maps, employing the two-class confusion matrix method to assess algorithm performance, allowing calculation of precision, recall, accuracy, F-score, and Pearson linear correlation coefficient between reference data and the map generated by the algorithm. The results reached average values of 0.74 for precision, 0.95 for recall, 0.77 for accuracy, 0.79 for F-score, and 0.56 for Pearson linear correlation coefficient, indicating superior algorithm performance in identifying weeds with projected ground areas larger than 400 cm². Weed mapping proves to be an effective and promising technique for localized management, enabling reduced herbicide volume, production costs, and environmental impact from spraying.

KEYWORDS: sustainable agriculture; weed detection; artificial intelligence

INTRODUÇÃO

O uso mundial de agrotóxicos apresentou um crescimento de 50% na década de 2010 em comparação com a década de 1990, chegando a 7,2 milhões de toneladas de produtos formulados e registrou um mercado global de US$ 41,1 bilhões em 2020 (FAO, 2022). A expansão na utilização de agrotóxicos é uma questão preocupante, tanto para os custos de produção quanto para as questões ambientais. Por isso, o controle fitossanitário adequado das plantas daninhas é essencial e pode contribuir para reduzir

a quantidade utilizada de agrotóxicos (VAN DEN BERG et al., 2020), além de desempenhar um papel crucial na produtividade das colheitas e na redução dos custos de produção (VITORINO et al., 2017).

Nesse sentido, o mapeamento preciso dessas plantas invasoras, por meio de aeronaves remotamente pilotadas (ARP) equipadas com câmeras, constitui uma técnica eficaz para o manejo localizado, permitindo a redução do volume de herbicidas aplicados, dos custos de produção e do impacto ambiental gerado pelas pulverizações, uma vez que a distribuição dessas plantas no campo apresenta um perfil heterogêneo (LAMB; BROWN, 2001). Para viabilizar essa abordagem, uma alternativa é utilizar mapas de aplicação localizada de herbicidas, confeccionados por algoritmos de inteligência artificial (IA), utilizando ferramentas de sensoriamento remoto para identificar a presença ou a ausência de plantas daninhas no campo.

OBJETIVOS

O presente estudo tem como objetivo avaliar o desempenho de um algoritmo classificador na geração de mapas para aplicação localizada de herbicidas, analisando e comparando os acertos e erros observados nos mapas de aplicação localizada de herbicidas com os dados amostrados na lavoura.

MATERIAL E MÉTODOS

O experimento foi realizado entre agosto e setembro de 2022 no município de Piraju (23º11'37" S, 49º23'02" W), no estado de São Paulo, em quatro talhões (A1, A2, A3 e A4) de áreas comerciais produtoras de soja de primeira safra e milho de segunda safra, com áreas de 87 ha, 85 ha, 65 ha e 56 ha. A altitude média da área é de 646 m e o solo Latossolo Vermelho. O clima regional é subtropical úmido (Cfa), conforme classificação climática de Köppen (1931), com temperatura e precipitação médias anuais de 20 ºC e 1283,6 mm, respectivamente.

A aquisição das imagens georreferenciadas se deu por meio de voos nos talhões com um ARP de asas fixas modelo eBee X, classe 3, sobrevoando a uma altura média de 110 metros do solo. Ao ARP foi acoplada uma câmera RGB modelo S.O.D.A de 24 MP, eletronicamente integrada e controlada automaticamente. O plano de voo e as configurações necessárias para aquisição das imagens foram realizados pelo software eMotion 3 (versão 3.14). A sobreposição lateral e longitudinal das imagens foi definida em 65% e 75% respectivamente, para gerar imagens com GSD (ground sample distance) de 2,5 cm/pixel.

As imagens obtidas no levantamento aéreo tiveram suas coordenadas GNSS (Global Navigation Satellite System) corrigidas pelo método cinemático pós-processado (PPK), conforme Zhang et al. (2019), utilizando um receptor GNSS como base fixa para coleta estática de coordenadas. A base foi instalada em locais limpos e sem obstáculos para evitar interferências na recepção dos sinais de satélites, com tempo mínimo de coleta de três horas para cada voo.

Após a coleta dos dados do receptor GNSS, os arquivos foram convertidos para o formato RINEX (Receiver Independent Exchange Format), cujo objetivo é permitir que os dados coletados por diferentes receptores GNSS possam ser processados e analisados por diferentes programas de pós-processamento. Foi utilizado o serviço online para pós-processamento de dados GNSS do Instituto Brasileiro de Geografia e Estatística (IBGE, 2022). As informações do relatório do posicionamento por ponto, fornecidas após o processamento dos dados pelo IBGE foram utilizadas para realizar a correção das coordenadas GNSS das imagens capturadas durante os voos. Por fim, foi gerado o ortomosaico, que é um mapa aéreo georreferenciado criado a partir da fusão das imagens aéreas capturadas durante o voo.

Foram coletados dados de pontos de referência nos talhões, também denominado "Verdade de Campo", logo após o término de cada voo. Os dados de referência coletados corresponderam à

presença de plantas daninhas (positiva) e ausência (negativa) observadas em campo para cada ponto amostral. Foi utilizado um receptor GNSS com precisão centimétrica para navegação e marcação dos pontos georreferenciados da área.

Foram definidos 3 tratamentos em função do tamanho das plantas daninhas: Pequena (P) com uma área projetada no solo de até 400 cm²; Média (M), com áreas maiores que 400 e menores 900 cm² e Grande (G), com áreas superiores a 900 e até 1600 cm². Em cada ponto amostral de presença foi realizado a classificação da planta, utilizando gabaritos com áreas de 400 cm², 900 cm² e 1600 cm².

Foi utilizado o delineamento em blocos casualizados, em que cada talhão representa um bloco, sendo o experimento composto por quatro blocos e três tratamentos, considerando plantas daninhas pequenas, médias e grandes. A execução do plano amostral por tratamento se deu realizando a coleta de 30 amostras, sendo 15 de presença e 15 de ausência em cada bloco, totalizando 120 parcelas por tratamento e 360 no total.

Os ortomosaicos com coordenadas GNSS com precisão centimétrica das quatro áreas experimentais, gerados com as imagens do aerolevantamento, foram disponibilizadas para a empresa "A" gerar os mapas de aplicação localizada de herbicidas. Para avaliar o mapa gerado foi utilizada a matriz de confusão, que oferece uma medida efetiva do modelo de classificação, ao mostrar o número de classificações corretas e as classificações preditas para cada classe em um determinado conjunto de dados, dessa forma permitiu uma análise mais detalhada do que a mera proporção de classificações corretas.

Os vetores de ponto do mapa verdade de campo e do mapa gerado pelo algoritmo classificador foram exportados para o software QGIS Desktop (versão 3.10.12) para avaliação das classificações realizadas pelo algoritmo. A análise da matriz de confusão gerou 4 classes:

Verdadeiro Positivo (VP): ocorre quando o mapa de aplicação localizada indicou presença de plantas daninhas e nesse mesmo local no mapa de verdade de campo foi evidenciado presença.

Verdadeiro Negativo (VN): ocorre quando o mapa de aplicação localizada indicou ausência de plantas daninhas e nesse mesmo local no mapa de verdade de campo foi constatado ausência.

Falso Positivo (FP): ocorre quando o mapa de aplicação localizada indicou presença de plantas daninhas e nesse mesmo local no mapa de verdade de campo foi evidenciado ausência.

Falso Negativo (FN): ocorre quando o mapa de aplicação localizada indicou ausência de plantas daninhas e nesse mesmo local no mapa de verdade de campo foi constatado presença.

Utilizando os valores de VP, VN, FP e FN obtidos na matriz de confusão, foi possível calcular e analisar os indicadores de desempenho do algoritmo classificador, conforme as equações:

$$\text{Precisão} = VP / (VP+FP) \quad (1)$$

$$\text{Revocação} = VP / (VP+FN) \quad (2)$$

$$\text{Acurácia} = (VP+VN) / (VP+VN+FP+FN) \quad (3)$$

$$\text{F-score} = ((2x\text{PrecisãoxRevocação})) / ((\text{Precisão}+\text{Revocação})) \quad (4)$$

Em que: VP - verdadeiro positivo; VN - verdadeiro negativo; FP - falso positivo e FN - falso negativo. Essas medidas de desempenho são índices que variam de 0 a 1.

Além da matriz de confusão e dos indicadores de desempenho, foram geradas três matrizes de correlação linear de Pearson, referentes às presenças das plantas daninhas e às ausências, uma para cada um dos três tratamentos. A análise foi realizada utilizando o software Minitab (versão 19.2020.1), com um nível de confiança (NC) de 95% entre os mapas e a significância de "r" verificada com probabilidade de 5%.

RESULTADOS E DISCUSSÃO

Os indicadores de desempenho precisão, revocação, acurácia, F-score e correlação linear de Pearson foram utilizados para avaliar um algoritmo classificador. Contudo, no contexto agrícola, em que a pulverização de herbicidas em área total é praticada em larga escala, a revocação se mostrou o indicador mais relevante, visto que considera a capacidade de identificar (VP) e de não identificar (FN) as plantas daninhas no campo. Os valores de revocação mostraram que a resolução das imagens utilizadas ou tamanho das plantas daninhas presentes nas áreas afetam o desempenho do algoritmo, visto que quanto maior a resolução ou o tamanho das plantas daninhas, maior o valor da revocação. Este fato pode ser explicado pelo motivo que plantas maiores ou resolução de imagens melhores possibilitam a distinção mais contundente entre plantas daninhas e demais elementos presentes na área, como solo descoberto ou palhada.

Os números de acertos VP e VN, assim como os erros FP e FN, relacionados às classificações corretas ou incorretas da presença ou ausência de planta daninha, foram extraídos da matriz de confusão, conforme o trabalho de Ahmad et al. (2021), em que a matriz de confusão forneceu um relatório detalhado do desempenho dos algoritmos avaliados para identificação de plantas daninhas em imagens RGB no sistema de produção de milho e soja no meio-oeste dos Estados Unidos. Esses dados possibilitaram o cálculo das médias dos indicadores de desempenho: precisão, revocação, acurácia, F-score e correlação linear de Pearson (Tabela 1).

Tabela 1. Números de acertos (VP e VN) e erros (FP e FN), extraídos da matriz de confusão e média dos indicadores de desempenho (precisão, revocação, acurácia, F-score e correlação linear de Pearson) do algoritmo classificador.

Tratamento	Tamanho de planta (cm²)	VP	VN	FP	FN	Precisão	Revocação	Acurácia	F-score	Correlação
T1 - PDP	400	43	37	23	17	0,6515	0,7167	0,6667	0,6825	0,335***
T2 - PDM	900	51	42	18	9	0,7391	0,8500	0,7750	0,7907	0,556***
T3 - PDG	1600	57	32	28	3	0,6706	0,9500	0,7417	0,7862	0,532***

***Significativo a 0,001; **Significativo a 0,01; *Significativo a 0,05; ns = Não significativo

PDP: Plantas daninhas pequenas (área ≤ 400 cm²)

PDM: Plantas daninhas médias (400 cm² > área ≤ 900 cm²)

PDG: Plantas daninhas grandes (> 900 cm² área ≤ 1600 cm²)

O tratamento 2 obteve a maior média de precisão, atingindo o valor de 0,7391, seguido do tratamento 3, registrando o valor 0,6706 e, por fim, o tratamento 1 apresentou a menor a média, obtendo 0,6515 de precisão. Islam et al. (2021) testaram três algoritmos de detecção de plantas daninhas em um campo de pimenta australiano usando imagens aéreas de uma câmera RGB de 12,4 MP montada em um ARP. Um dos algoritmos obteve precisão de 0,62, sustentando os resultados deste estudo.

O tratamento 3 obteve a maior média de revocação, seguido do tratamento 2 e tratamento 1, com valores de 0,9500; 0,8500 e 0,7167, respectivamente. Os resultados mostram que quanto maior a área da planta maior é o valor de VP e menor é o valor de FN e, consequentemente, maior o valor de revocação. A revocação é a métrica crucial neste estudo, pois utiliza VP e FN, indicando a capacidade do algoritmo em identificar plantas daninhas com poucos falsos negativos. Mattivi et al. (2021) alcançaram revocações entre 0,53 e 0,72 em ortomosaicos com resolução de 1,1 cm/pixel, enquanto Valente et al. (2019) obtiveram 0,91 com resolução de 0,6 cm/pixel, corroborando a importância da resolução de imagem e tamanho das plantas para o desempenho do algoritmo.

No estudo de Reedha et al. (2022), a acurácia não foi empregada na avaliação dos algoritmos de detecção de plantas daninhas, devido à sua dependência de valores de VNs, os quais não são considerados relevantes nesse contexto. Os autores reconhecem que a não consideração dos VNs pode ser problemática em algumas tarefas de classificação, mas argumentam que na detecção de plantas daninhas, é preferível superdetectar a subdetectar. Isso está alinhado com os resultados deste estudo, enfatizando a importância da revocação na avaliação de mapas para aplicação localizada de herbicidas. Embora a acurácia isoladamente sugira melhor desempenho no tratamento 2, devido ao maior número de FP no tratamento 3, é essencial considerar a preferência por superdetecção de plantas daninhas nesse contexto. Isso sustenta a ideia de que maior resolução de imagens ou tamanho das plantas resultam em melhor desempenho do algoritmo.

Ao analisar os resultados, os modelos avaliados por Ahmad et al. (2021) demonstraram um intervalo de F-score entre 0,81 e 0,99, com média de 0,93, indicando um desempenho superior em estruturas de aprendizado profundo. Isso sugere que abordagens baseadas em aprendizado profundo podem ser eficazes na identificação de plantas daninhas, oferecendo um equilíbrio entre desempenho e tempo de treinamento. Os resultados de F-score neste estudo destacam a importância da resolução das imagens e do tamanho das plantas na área para o desempenho do algoritmo. No entanto, há espaço para melhorias, especialmente na detecção de plantas daninhas com áreas menores que 400 cm².

Os resultados de Burgos-Artizzu et al. (2009), ao estimar a cobertura de plantas daninhas em campos de cultivo com imagens digitais de resolução de 0,006 cm/pixel, apresentaram coeficientes de correlação de Pearson entre 0,587 e 0,797, considerados de grande magnitude (Cohen, 1988). Em comparação, os coeficientes obtidos neste estudo para o tratamento 2 e tratamento 3, também foram grandes, embora nominalmente menores. Essa diferença é principalmente atribuída à resolução das imagens utilizadas (2,5 cm/pixel), sugerindo que uma resolução maior ou tamanhos maiores de plantas daninhas podem melhorar o desempenho do algoritmo.

CONCLUSÃO

O estudo avaliou o desempenho de um algoritmo classificador de presença de plantas daninhas em mapas para aplicação de herbicidas, considerando diferentes tamanhos plantas. A análise incluiu indicadores de desempenho como precisão, revocação, acurácia, F-score e correlação linear de Pearson. Os resultados indicaram melhor desempenho do algoritmo para plantas maiores. A revocação se destacou como o indicador mais relevante, dada sua sensibilidade a falsos negativos. O estudo sugere que algoritmos de IA têm potencial para essa aplicação, mas ajustes são necessários, especialmente para plantas menores que 400 cm².

REFERÊNCIAS

AHMAD, A.; SARASWAT, D.; AGGARWAL, V.; ETIENNE, A.; HANCOCK, B. Performance of deep learning models for classifying and detecting common weeds in corn and soybean production systems. **Computers and Electronics in Agriculture**, v. 184, p. 106081, 2021.

BURGOS-ARTIZZU, X. P.; RIBEIRO, A.; TELLAECHE, A.; PAJARES, G.; FERNÁNDEZ-QUINTANILLA, C. Improving weed pressure assessment using digital images from an experience-based reasoning approach. **Computers and Electronics in Agriculture**, v. 65, n. 2, p. 176-185, 2009.

FAO. Pesticides use, pesticides trade and pesticides indicators Global, regional and country trends, 1990-2020. **FAOSTAT Analytical Briefs**, v. 46, 2022.

IBGE - PPP - Serviço online para pós-processamento de dados GNSS, 2022. Disponível em: <https://www.ibge.gov.br/geociencias/informacoes-sobre-posicionamento-geodesico/servicos-para-posicionamento-geodesico/16334-servico-online-para-pos-processamento-de-dados-gnss-ibge-ppp.html?=&t=processar-os-dados>. Acesso em: 20 mar. 2024.

ISLAM, N.; RASHID, M. M.; WIBOWO, S.; XU, C.-Y.; MORSHED, A.; WASIMI, S. A.; MOORE, S.; RAHMAN, S. M. Early weed detection using image processing and machine learning techniques in an australian chilli farm. **Agriculture**, v. 11, n. 5, p. 387, 2021.

KÖPPEN, W. P. **Grundriss der klimakunde**. Berlin: W. de Gruyter, 1931.

LAMB, D. W.; BROWN, R. B. PA-Precision Agriculture. **Journal of Agricultural Engineering Research**, v. 78, n. 2, p. 117-125, 2001

MATTIVI, P.; PAPPALARDO, S. E.; NIKOLI?, N.; MANDOLESI, L.; PERSICHETTI, A.; DE MARCHI, M.; MASIN, R. Can commercial low-cost drones and open-source GIS technologies be suitable for semi-automatic weed mapping for smart farming? A case study in NE Italy. **Remote Sensing**, v. 13, n. 10, p. 1869, 2021.

REEDHA, R.; DERICQUEBOURG, E.; CANALS, R.; HAFIANE, A. Transformer neural network for weed and crop classification of high resolution UAV images. **Remote Sensing**, v. 14, n. 3, p. 592, 2022.

VALENTE, J.; DOLDERSUM, M.; ROERS, C.; KOOISTRA, L. Detecting *RUMEX* obtusifolius weed plants in grasslands from UAV rgb imagery using deep learning. **ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. IV-2/W5, p. 179-185, 2019.

VAN DEN BERG, H.; GU, B.; GRENIER, B.; KOHLSCHMID, E.; AL-ERYANI, S.; DA SILVA BEZERRA, H. S.; NAGPAL, B. N.; CHANDA, E.; GASIMOV, E.; VELAYUDHAN, R.; YADAV, R. S. Pesticide lifecycle management in agriculture and public health: Where are the gaps? **Science of the Total Environment**, v. 742, 2020.

VITORINO, H. dos S.; JUNIOR, A. C. da S.; GONÇALVES, C. G.; MARTINS, D. Interference of a weed community in the soybean crop in functions of sowing spacing. **Revista Ciência Agronômica**, v. 48, n. 4, p. 605-613, 2017.

ZHANG, H.; ALDANA-JAGUE, E.; CLAPUYT, F.; WILKEN, F.; VANACKER, V.; VAN OOST, K. Evaluating the potential of post-processing kinematic (PPK) georeferencing for UAV-based structure- from-motion (SfM) photogrammetry and surface change detection. **Earth Surface Dynamics**, v. 7, n. 3, p. 807-827, 2019.

CARACTERIZAÇÃO DA PULVERIZAÇÃO DE DRONES CLASSE III E II EM VINHEDOS COM DOIS SISTEMAS DE CONDUÇÃO

Lillian Espindola Müller [1]; Fabio Rossi Cavalcanti [2]
[1]Doutoranda em Fitotecnia. Porto Alegre/RS. Universidade Federal do Rio Grande do Sul; [2]Pesquisador A. Bento Gonçalves/RS. Embrapa Uva e Vinho

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
As aeronaves remotamente pilotadas (RPA), conhecidas popularmente como drones, estão sendo cada vez mais adotadas para a aplicação fitossanitária. Este estudo explora a eficácia comparativa entre o uso de duas classes de drones e os métodos tradicionais de pulverização terrestre em vinhedos, focando na qualidade da dispersão e na abrangência da cobertura de dossel. Resultados indicam que, com um método específico para cada tecnologia de aplicação, os drones podem aplicar produtos fitossanitários e outros agentes químicos de maneira precisa, contribuindo para a prevenção de doenças nas plantações e para a redução do impacto ambiental negativo.

PALAVRAS-CHAVE: tecnologia de aplicação; aeronave remotamente pilotada; controle de doenças

ABSTRACT
Remotely piloted aircraft (RPA), popularly known as drones, are increasingly being adopted for phytosanitary application. This study explores the comparative effectiveness between the use of two classes of drones and traditional ground spraying methods in vineyards, focusing on the quality of dispersal and the scope of canopy coverage. Results indicate that, with a specific method for each application technology, drones can apply phytosanitary products and other chemical agents precisely, contributing to the prevention of diseases in plantations and the reduction of negative environmental impacts.

KEYWORDS: application technology; remotely piloted aircraft; disease control

INTRODUÇÃO

A utilização de aeronaves remotamente pilotadas na agricultura, especialmente para pulverização em vinhedos, visa superar as limitações de métodos tradicionais como a pulverização manual ou por trator, que são ineficientes e propensos à poluição ambiental (SANCHAVAT *et al*., 2017). Os drones permitem uma aplicação localizada além do monitoramento avançado das culturas através de sensores de imagem, contribuindo para a detecção precoce de doenças (HERBST *et al*., 2020; MATESE *et al*., 2016). A calibração e validação das pulverizações, fundamentais para a eficácia do tratamento, podem ser aferidas com o uso de cartões hidrossensíveis, que oferecem dados sobre a deposição da pulverização (MATTHEWS *et al*., 2016; BRANDOLI *et al*., 2021). Desafios como a redução do impacto ambiental ocasionado por aplicações inadequadas e a distribuição uniforme e precisa das gotas de pulverização ainda persistem, exigindo a definição de parâmetros operacionais adequados para a tecnologia de aplicação utilizada a fim de melhorar a qualidade da pulverização (CAVALCANTI; MULLER, 2023). Este estudo teve por objetivo a caracterização da pulverização por aeronaves remotamente pilotadas Classe III (peso máximo de decolagem maior que 250 g e até 25 kg) e II (peso máximo de decolagem maior que 25 kg e até 150 kg) em vinhedos, buscando aperfeiçoar o controle fitossanitário através de diferentes taxas de aplicação e configurações de pulverização.

OBJETIVOS

MATERIAL E MÉTODOS

Em estudo realizado na Embrapa Uva e Vinho, no município de Bento Gonçalves no estado do Rio Grande do Sul (RS), foram testadas eficácias de pulverização por drone em vinhedos de 'Cabernet Sauvignon' (*Vitis vinifera* L.) e 'Niágara Rosada' (*Vitis labrusca*), configurados em sistema de condução espaldeira, no qual as plantas são guiadas verticalmente em linhas horizontais de fios de arame e no sistema de condução latada, onde as videiras são conduzidas horizontalmente sobre estruturas de suporte em forma de treliça, respectivamente. Os vinhedos apresentam espaçamento de 3,0 m x 2,0 m, com orientações e inclinações específicas. Utilizaram-se drones classe III e II, segundo a classificação da Agência Nacional de Aviação Civil (ANAC), sendo o drone classe III equipado com pontas de pulverização hidráulica jato leque 110.015 e o drone classe II equipado com aspersor centrífugo atomizador duplo modelo LX8060SZ. Para o tratamento fitossanitário terrestre foi utilizador o pulverizador Acefibras modelo 500L com pontas de pulverização MGA 40025. Seis ensaios de pulverização aérea, utilizando-se água, foram aplicados em diferentes volumes (20L ha^{-1}, 30L ha^{-1}, 40L ha^{-1}, 90L ha^{-1}) e métodos (linear, ortogonal), durante a fase inicial de florescimento e ao final do período produtivo. As deposições foram avaliadas com cartões hidrossensíveis posicionados no dossel, direcionados para os pontos cardeais, em um delineamento inteiramente casualizado, considerando os ensaios de pulverização, os sistemas de condução dos vinhedos (espaldeira e latada) e as orientações geográficas, com seis repetições. Após a coleta e digitalização, os cartões foram analisados pelo software Gotas®, com foco em variáveis como o número de gotas e de diâmetros, densidade e cobertura. Análises estatísticas, incluindo não paramétricas (Kruskal-Wallis, Wilcoxon) e paramétricas (ANOVA, Tukey) foram aplicadas, com resultados apresentados em gráficos de radar via R, adotando um nível de significância de 5%.

RESULTADOS E DISCUSSÃO

As análises revelaram que, embora as aplicações com o drone classe II em espaldeira tenham apresentado desempenhos próximos entre si, com destaque para as passagens de 40L ha^{-1} que mostraram os melhores indicadores de qualidade de pulverização, todas ficaram abaixo dos ideais para controle efetivo de doenças que, segundo CHAIM (2009), são deposições de gotas com densidade superior a 70 gotas por centímetro quadrado. A aplicação em latada, por sua vez, resultou em padrões inferiores, sugerindo a necessidade de abordagens diferenciadas para cada sistema de condução. Já o drone classe III apresentou um padrão geral de pulverização abaixo dos níveis ideais, tanto em comparação com o sistema tratorizado quanto com os padrões teóricos ideais para uma pulverização eficaz no controle de doenças. Apesar de um leve incremento de desempenho apresentado ao se utilizar a taxa de aplicação de 90L ha^{-1}, a aplicabilidade e a viabilidade comercial seriam fatores questionáveis uma vez que o rendimento operacional poderia ser comprometido, elevando assim os custos para o tratamento fitossanitário. Ambas as classes de drones seguiram as normas operacionais estabelecidas pelos órgãos regulamentadores, com cuidados específicos para minimizar a deriva e aperfeiçoar a eficácia da pulverização. A análise estatística não indicou variações significativas na deposição das gotas em função da orientação dos cartões hidrossensíveis, apontando para uma aplicação uniforme em todas as direções. Os resultados enfatizam a complexidade da tecnologia de aplicação via drones, destacando a importância do tamanho e da distribuição das gotas para a eficiência da aplicação. Para aumentar a eficiência recomenda-se desenvolver métodos específicos para cada sistema de condução. Drones classe II, com duplo rotor coaxial e atomizador de disco centrífugo, são adequados para controle de doenças em vinhedos com sistema de condução em espaldeira, exigindo, porém, ao menos três aplicações sequenciais com uma taxa de 40L ha^{-1}. Embora drones classe III tenham mostrado eficácia inferior aos ideais de controle de doenças, ajustes nas taxas e técnicas de aplicação podem melhorar seu desempenho. A pesquisa sugere a continuidade dos estudos a fim de aperfeiçoar a tecnologia de aplicação e os parâmetros adequados para cada

equipamento, especialmente para drones classe III, objetivando melhorar a deposição no dossel, com densidade de gotas e cobertura adequada para o controle efetivo de doenças, considerando a viabilidade econômica e a sustentabilidade do uso de drones, alinhando as práticas de pulverização às especificidades de cada sistema de condução de vinhedos.

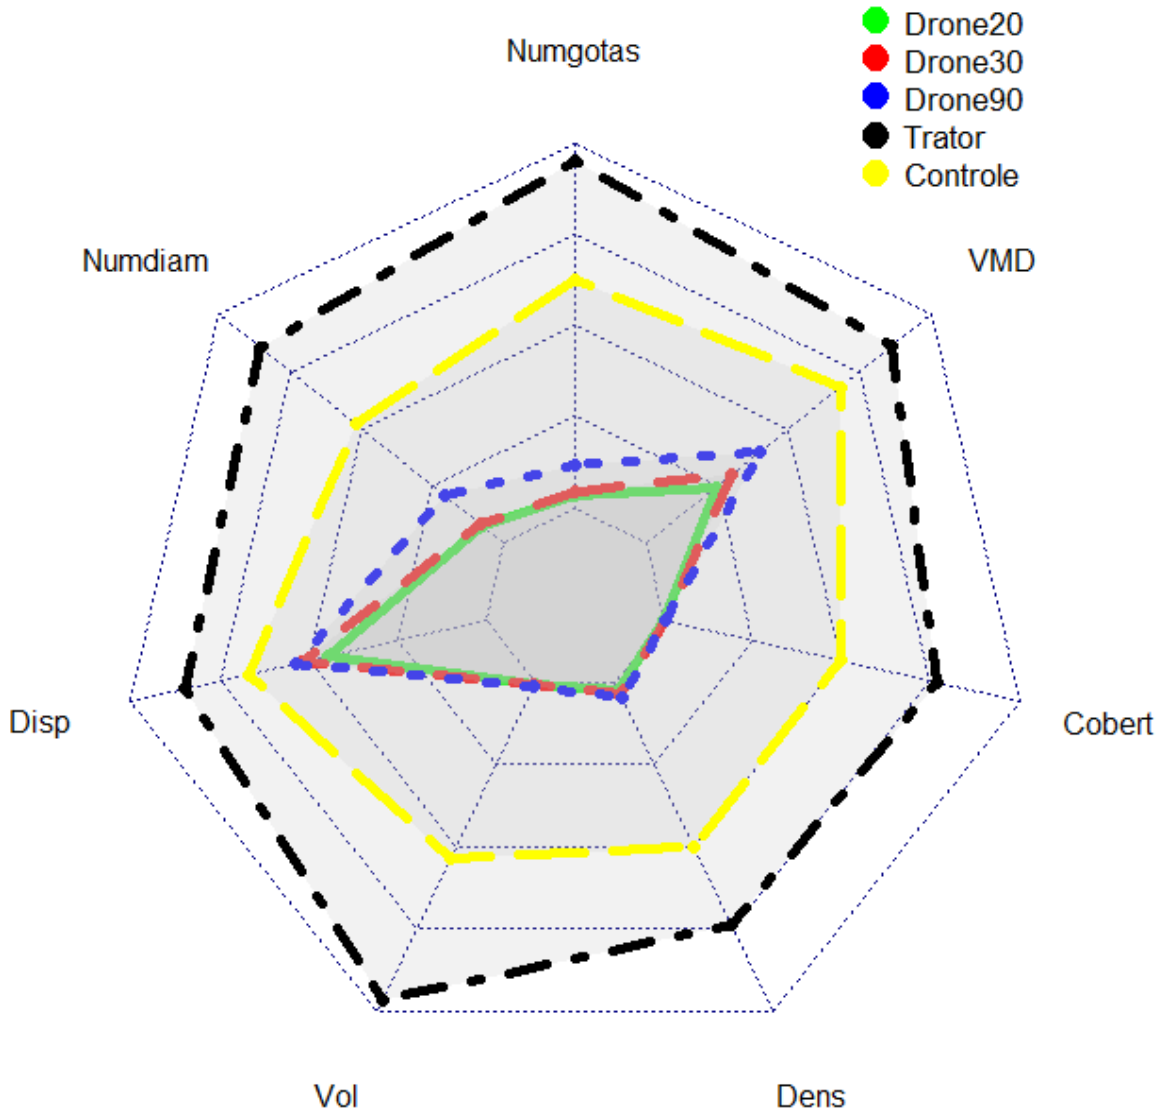


FIGURA 1. Perfis de variáveis descritoras da qualidade de pulverização realizada por drone classe III, equipado com pontas de pulverização hidráulica jato leque 110.015, em taxas de aplicação de 20, 30 e 90L ha-1, e terrestre por pulverizador Acefibras, modelo 500L equipado com ponta de pulverização MGA 40025, puxado em marcha 2ª simples (2S) por trator marca Yanmar 1050 (modelo 1990). O traço amarelo indica a recomendação de maior eficiência na pulverização para o controle de doença (CHAIM, 2009; MANGADO et al., 2013).

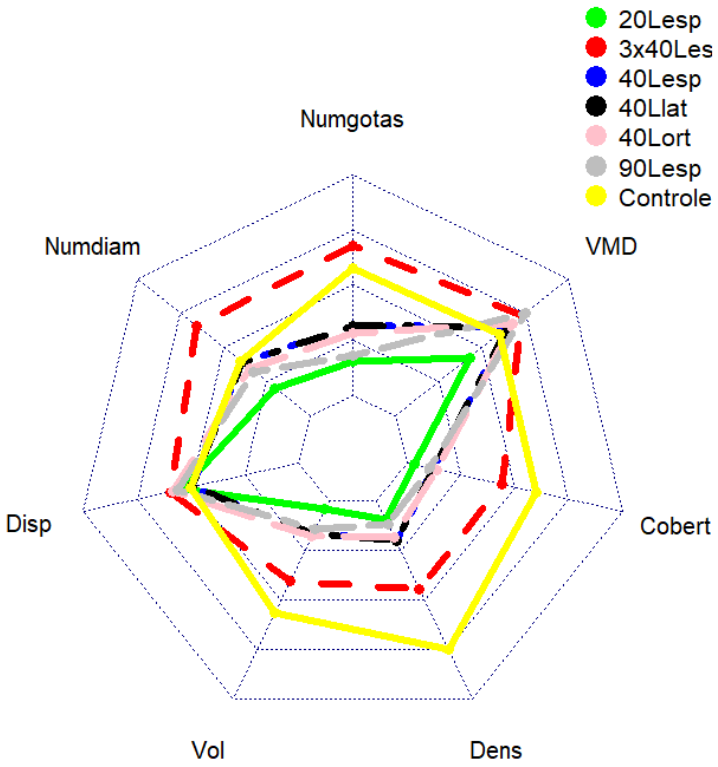


FIGURA 2. Perfis de variáveis descritoras da qualidade de pulverização realizada por drone classe II com duplo rotor coaxial e atomizador duplo de disco centrífugo. Os tratamentos testados foram: 20L ha-1 em espaldeira (20Lesp), três aplicações de 40L ha-1 em espaldeira (3x40Les), 40L ha-1 em espaldeira (40Lesp), 40L ha-1 em latada (40Llat), 40L ha-1 em espaldeira com aplicação em sentido ortogonal (40Lort) e 90L ha-1 em espaldeira (90Lesp). O traço amarelo indica a recomendação de maior eficiência na pulverização para o controle de doença (CHAIM, 2009; MANGADO et al., 2013).

CONCLUSÃO

Para o controle eficaz de doenças em vinhedos conduzidos em espaldeira, recomenda-se o uso de drones classe II equipados com duplo rotor coaxial e atomizador duplo de disco centrífugo. Essa recomendação tem por base a necessidade de realizar no mínimo três (3) aplicações paralelas às linhas do vinhedo, com uma taxa de aplicação mínima de 40L ha^{-1}, conforme as configurações testadas neste estudo.

REFERÊNCIAS

BRANDOLI, B.; SPADON, G.; ESAU, T.; HENNESSY, P.; CARVALHO, A.C.P.; AMER-YAHIA, S.; RODRIGUES-JR, J.F. Drop Leaf: a precision farming smartphone tool for real-time quantification of pesticide application coverage. **Computers and Electronics in Agriculture**, v. 180, p. 105906, https://doi.org/10.1016/j.compag.2020.105906, 2021.

CAVALCANTI, F.R.; MULLER, L.E. Caracterização da pulverização por drone classe III com ponta 110-015 em dois sistemas de condução de videira. **Embrapa Uva e Vinho** (Embrapa Uva e Vinho. Circular Técnica 165), 11p. 2023.

CHAIM, A. Manual de tecnologia de aplicação de agrotóxicos. Brasília, DF: **Embrapa Informação Tecnológica**, 2009. 78 p.

HERBST, A.; BONDS, J.; WANG, Z.; ZENG, A.; HE, X.; GOFF, P. The influence of unmanned agricultural aircraft system design on spray drift. **Journal für Kulturplanzen**, v. 72, n. 1, p. 1-11, 2020.

MANGADO, J.; ARAZURI, S.; ARNAL, P.; JARÉN, C.; LÓPEZ, A. Measuring the accuracy of a pesticide treatment by an image analyzer. **Procedia Technology**, v. 8, p. 498-502. 2013.

MATESE, A.; DI GENNARO, S.F.; BERTON, A. Assessment of a canopy height model (CHM) in a vineyard using UAV-based multispectral imaging. **International Journal of Remote Sensing**, v. 38, n. 8-10, p. 2150-2160, 2016.

MATTHEWS, G.A.; BATEMAN, R.; MILLER, P. Pesticide application methods (4th ed.). **Wiley-Blackwell**. https://doi.org/10.1002/9781118952779, 2016. 517p.

SANCHAVAT, H.B.; CHAUDHARY, H.S.; BHAUTIK, G.; SINGH, S.N. Field evaluation of a tractor mounted boom sprayer. **Agricultural Engineering Today**, v. 41, n. 4, p. 67-71, 2017.

MODELO DE ALERTA DE DOENÇA ENTREGA O INSTANTE E O GEORREFERENCIAMENTO PARA APLICAÇÃO PONTUAL DE FUNGICIDA

Fabio Rossi Cavalcanti [1]; Lillian Espindola Müller [2]
[1]Pesquisador A. Bento Gonçalves/RS. Embrapa Uva e Vinho; [2]Doutoranda em Fitotecnia. Porto Alegre/RS. Universidade Federal do Rio Grande do Sul

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
O estudo apresenta o módulo Embrapa/MAHM, uma ferramenta de alerta para míldio em vinhedos, que divide a área de cultivo em quadrantes e fornece alerta de risco por meio de mapa de cores. Utilizando dados de umidade e temperatura captados por meio de sensores de IoT dispostos em triangulação, o MAHM indica o nível de risco de doença por quadrante, produzindo subsídio para que sistemas de alerta indiquem a orientação espacial para um tratamento pontual de fungicida. Sua compatibilidade com plataformas de IoT de baixo custo, usando tecnologias como NB-IoT, LoRaWAN e SigFOX, torna-o uma solução promissora para o manejo mecanizado de doenças em vinhedos, pois abre a possibilidade de gerar *waypoints* para deslocamento de robôs de pulverização em um controle automatizado de doenças.

PALAVRAS-CHAVE: sistemas de alerta de doença; controle do míldio em videira;

ABSTRACT
This study presents the Embrapa/MAHM module, an alert tool for downy mildew in vineyards, which divides the cultivation area into quadrants and provides risk alerts through a color-coded map. Utilizing humidity and temperature data captured by IoT sensors arranged in triangulation, the MAHM indicates the disease risk level per quadrant, providing insights for alert systems to suggest spatial orientation for targeted fungicide treatment. Its compatibility with low-cost IoT platforms, using technologies like NB-IoT, LoRaWAN, and SigFOX, makes it a promising solution for mechanized disease management in vineyards, as it enables the generation of waypoints for the movement of spray robots in an automated disease control process.

KEYWORDS: disease alert systems; control of downy mildew on grapevines;

INTRODUÇÃO

A epidemiologia de plantas, focada no estudo das doenças vegetais e sua disseminação, é crucial para entender e controlar epidemias no campo. Fatores ambientais como umidade relativa, temperatura e pluviosidade desempenham papéis significativos na dinâmica de doenças, influenciando a favorabilidade para o desenvolvimento de patógenos. A modelagem matemática, combinada com avanço do sensoriamento digital e conectividade rural, permite monitorar esses fatores e gerar informações úteis para a prevenção de doenças. O algoritmo Embrapa/MAHM (INPI-BR512019992684-5, 2019) incorpora a aplicação desses conceitos, utilizando dados de microclima coletados por sensores de IoT para estimar e mapear o risco de doenças em vinhedos, subdividindo a área de cultivo em quadrantes georreferenciados. O paradigma de IoT trazido pelo Embrapa/MAHM utiliza microestações NB-IoT para coletar dados de umidade relativa e temperatura em triangulações, com as microestações distribuídas a fim de definir microclimas específicos. Essas microestações fornecem informações em tempo real para métodos que denominam os dados de favorabilidade de doença calculados pelo MAHM para geração de alertas georreferenciados de doença. Experimentos recentes envolvendo o caso de estudo (míldio da videira) validaram a eficácia do método de alerta

"O2" no controle do míldio, demonstrando a capacidade do MAHM/O2 em fornecer orientações precisas para o momento correto de aplicação do tratamento fitossanitário nos vinhedos (CAVALCANTI, 2021; CAVALCANTI *et al*., 2024). Essa integração de dados climáticos, modelagem matemática e sensoriamento de IoT promete não apenas aumentar o rendimento das colheitas e reduzir o uso de pesticidas, mas também garantir a segurança alimentar e promover a sustentabilidade na agricultura.

OBJETIVOS

MATERIAL E MÉTODOS

Em vinhedos experimentais de cultivares 'Isabel' e 'Niágara Rosada' da Embrapa Uva e Vinho, localizada no município de Bento Gonçalves no estado do Rio Grande do Sul (RS), e 'Chardonnay' e 'Cabernet Sauvignon' em três microrregiões do município de Pinto Bandeira (RS), foram conduzidos estudos envolvendo controle de míldio nas safras 2019/2020 até 2022/2023. As linhas dos vinhedos, orientadas de oeste para leste, possuíam inclinações diversas. Monitoramentos focaram em parcelas de cinco plantas, com espaçamento de 1 m entre plantas e 1,5 m entre fileiras. A incidência e severidade do míldio foram avaliadas visualmente em folhas e cachos, sendo a severidade categorizada em quatro classes e analisada estatisticamente após transformação angular. Para a calibração do método de alerta "O1" (CAVALCANTI, 2021) e, subsequentemente, "O2" (CAVALCANTI *et al*., 2024), dados de incidência de míldio foram coletados nos vinhedos experimentais durante as safras 2019/2020 a 2022/2023. Dados climáticos foram obtidos das redes de estação NB-IoT montadas nos municípios de Bento Gonçalves e Pinto Bandeira. Em caso de infecção, a análise envolveu a avaliação da incidência e severidade do míldio, calculando-se a variação de severidade (ΔID%) e a taxa linear de variação de severidade (tID%) em avaliações consecutivas, baseando-se nas parcelas definidas do monitoramento para calibração dos métodos.

RESULTADOS E DISCUSSÃO

O sistema MAHM/O2 destacou-se por sua capacidade de gerar alertas georreferenciados de míldio em vinhedos, utilizando dados de estações de IoT. Demonstrou ser uma ferramenta eficaz para o monitoramento e proteção dos vinhedos contra o míldio, reduzindo significativamente o número de aplicações de fungicidas. O MAHM/O2 apresenta uma interface visual intuitiva, com um mapa de cores que facilita a tomada de decisão para a aplicação de fungicidas, contribuindo com a sustentabilidade e a eficiência na agricultura. O sistema MAHM/O2 provou ser eficaz para a prevenção do míldio em vinhedos de Bento Gonçalves e Pinto Bandeira, eliminando a ocorrência da doença. Este sistema possibilitou uma redução no número de aplicações de fungicidas, alcançando de 15 a 37% nos vinhedos 'Isabel' e 'Niagara Rosada' para a safra 2021/2022, e de 15 a 63% para a mesma região na safra 2022/2023. No vinhedo 'Chardonnay', a redução foi ainda mais significativa, variando de 50 a 67% na safra 2022/2023 (Figuras 1 e 2). Esses resultados destacam a capacidade do MAHM/O2 de diminuir substancialmente o uso de fungicidas, comparado a métodos convencionais, adotando o critério do 'pior' alerta no quadrante sendo estendido para aplicação em todo o vinhedo. A integração futura de tecnologias como aprendizado de máquina e IA promete aprimorar a precisão dos alertas e facilitar a aplicação automatizada de fungicidas, alinhando o sistema às metas da Agricultura 5.0. Essas reduções estão em consonância com sistemas de alerta internacionais, evidenciando o potencial do MAHM/O2 no manejo eficiente e sustentável de doenças em culturas agrícolas.

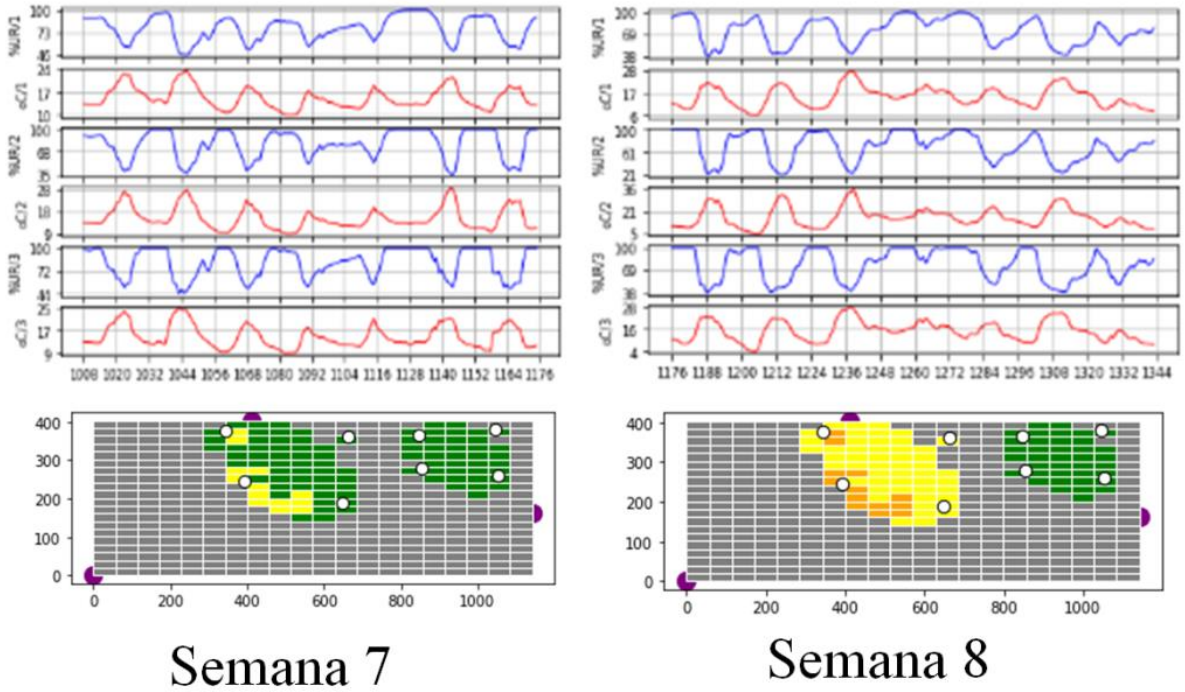


FIGURA 1. Perfis climáticos (oC, em vermelho, e % UR, em azul) e, abaixo, respectivos mapas temáticos gerados por um simulador MAHM/O2 (em Python) para o controle de míldio nos vinhedos 'Isabel' (vinhedo esquerdo) e 'Niágara Rosada' (vinhedo direito) da Embrapa Uva e Vinho, na safra 2022/23 (semanas 7 e 8, em detalhe). Para a emissão do alerta do método O2 foi adotada uma resolução de 20 x 20 quadrantes. Esquema de cores segue o critério de decisão definido para a versão do O2: vermelho, 'pulverização imediata'; amarelo, 'aguardar o próximo alerta: havendo novo alerta amarelo, pulverizar'; verde, 'não é necessária pulverização na semana corrente'; laranja, 'pulverização imediata pelo 2º amarelo em sequência'; azul, 'quadrantes protegidos por fungicida de 15 dias'. Para os experimentos de validação do timing, na indisponibilidade de robô de pulverização e/ou equipe com costal, adotou-se o critério do 'pior alerta' em um quadrante qualquer no vinhedo cadastrado, a pulverização seria imposta ao vinhedo inteiro pelo sistema usual: trator + implemento.

Vinhedos	[2]Semanas																		
	01	02	03	04	05	06	07	08	09	10	11	12	13	14	15	16	17	18	19	20
[1]'Chardonnay'			R																	
[3]Vinifera 1		R																		
Vinifera2	R																			
Vinifera3		R																		

[1] Vinhedo experimental em Pinto Bandeira/RS;
[2] Base de contagem semanal para geração dos alertas O2 e monitoramento das pulverizações de fungicidas;
[3] Informações fornecidas por empresa de apoio técnico a vinícolas;
R – semana da marcação de rebrota no vinhedo em questão.

Legenda para os princípios ativos utilizados:

Mancozeb (M)	
Dimetomorfe	
Cimoxanil+M	
Clorotalonil	
Metalaxil + M	
Estrubirulina	
Cuprico	
Oxatiapiprolina	

FIGURA 2. Comparativo entre esquemas utilizados em vinhedos de Vitis vinifera em Pinto Bandeira/RS para proteção contra Plasmopara viticola, na safra 2022/23. É possível observar redução de aplicações com relação a vinhedos seguindo esquemas de proteção não racionalizados.

CONCLUSÃO

A versão atual do MAHM/O2 (CAVALCANTI *et al*., 2024) foi capaz de lançar alertas para proteção total em vinhedos experimentais de dois municípios do RS, e em diferentes microrregiões e microclimas, com reduções de 15 a 60% na aplicação de calda. No entanto, apenas o momento correto de aplicação fitossanitária, fornecido pelo sistema, foi validado, sendo iminente a necessidade de avaliações para o georreferenciamento do algoritmo. Comparado a outros sistemas de alerta, o MAHM/O2 mostra reduções nas aplicações de fungicidas compatíveis com sistemas internacionais, evidenciando seu potencial no manejo eficaz de doenças e promovendo uma agricultura mais sustentável.

REFERÊNCIAS

CAVALCANTI, F. R. Algoritmo (MAHM) para alerta georreferenciado de doença em redes de sensoriamento IoT de microclima: calibração e teste de um método para míldio, em dois vinhedos. Bento Gonçalves, RS: **Embrapa Uva e Vinho**, agosto 2021. 25 p. (Embrapa Uva e Vinho. Circular Técnica, 124).

CAVALCANTI, F.R; BOTTON, M.; FIORAVANÇO, J.C. Atualizações de alertas para controle do míldio da videira com o Algoritmo Embrapa/MAHM. Bento Gonçalves: **Embrapa Uva e Vinho**, 2024. (Embrapa Uva e Vinho. Circular Técnica). No Prelo.

VARIABILIDADE ESPACIAL DA ÁGUA DISPONÍVEL E DA CONDUTIVIDADE ELÉTRICA APARENTE NO SOLO PARA DEFINIÇÃO DE ZONAS DE MANEJO DE IRRIGAÇÃO

André Müllich [1]; Juliano Dalcin Martins [3]; Luciano Zucuni Pes [2]; Ivan Carlos Maldaner [2]; Marcelo Silveira de Farias [2]

[1]Bolsista. Av. Roraima nº 1000 Cidade Universitária Bairro - Camobi, Santa Maria - RS, 97105-900. Universidade Federal de Santa Maria; [2]Docente. Av. Roraima nº 1000 Cidade Universitária Bairro - Camobi, Santa Maria - RS, 97105-900. Colégio Politécnico da Universidade Federal de Santa Maria; [3]Docente. Av. Roraima nº 1000 Cidade Universitária Bairro - Camobi, Santa Maria - RS, 97105-900. Universidade Federal de Santa Maria

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A disponibilidade de água no solo é uma importante variável para o manejo da irrigação e a sua mensuração geralmente é realizada por meio de amostragens de solo aleatórias ao longo dos talhões agrícolas. No entanto, os parâmetros físico-hídricos do solo, incluindo o conteúdo de água, podem variar nas diferentes regiões de um talhão agrícola, principalmente nos casos em que a topografia é irregular. Neste sentido, este trabalho teve como objetivo identificar a variabilidade espacial da água disponível e da condutividade elétrica aparente no solo de um talhão agrícola irrigado por pivô central e propor estratégias de irrigação em taxa variável. O estudo foi realizado na área didático-experimental do Colégio Politécnico da Universidade Federal de Santa Maria, em Santa Maria - RS. A água disponível foi determinada por meio da coleta de amostras de solo na camada de 0 a 20 cm e posterior análise em laboratório. A condutividade elétrica aparente do solo foi determinada com o auxílio do equipamento VERIS U3, também na camada de 0 a 20 cm. Os mapas de variabilidade espacial da água disponível e da condutividade elétrica aparente foram gerados com o uso do Software QGIS. O talhão agrícola analisado apresentou variabilidade na água disponível e na condutividade elétrica aparente, visíveis nos mapas gerados. Com o uso de tecnologia embarcada no pivô de irrigação é possível irrigar em taxa variável por setores e otimizar o uso da água no talhão.

PALAVRAS-CHAVE: Manejo localizado; Otimização de recursos; Atributos físico-hídricos

ABSTRACT

The availability of water in the soil is an important variable for irrigation management, and its measurement is generally carried out through random soil samplings across agricultural fields. However, the physical-hydraulic parameters of the soil, including water content, can vary in different regions of an agricultural field, especially in cases where the topography is irregular. In this regard, this study aimed to identify the spatial variability of available water and apparent electrical conductivity in the soil of a pivot-irrigated agricultural field and to propose variable-rate irrigation strategies. The study was conducted in the didactic-experimental area of the Polytechnic College of the Federal University of Santa Maria, in Santa Maria - RS. Available water was determined by collecting soil samples from the 0 to 20 cm layer and subsequent laboratory analysis. Apparent electrical conductivity of the soil was determined using the VERIS U3 equipment, also in the 0 to 20 cm layer. Maps of spatial variability of available water and apparent electrical conductivity were generated using the QGIS Software. The agricultural field analyzed showed variability in available water and apparent electrical conductivity, visible in the generated maps. With the use of technology embedded in the irrigation pivot, it is possible to irrigate at variable rates and optimize water use in the field.

KEYWORDS: ;;

INTRODUÇÃO

A irrigação é uma prática utilizada de forma a complementar à disponibilidade de água que naturalmente é promovida pela precipitação aos cultivos agrícolas. A irrigação é uma técnica de uso da água de elevado consumo e que demanda de cuidados especiais para que se tenha o aproveitamento racional, com o mínimo desperdício (SETTI et al., 2001). Devido a isso, vem sendo crescente o emprego das ferramentas da Agricultura de Precisão (AP) na área da irrigação. A AP compreende um conjunto de ferramentas e tecnologias que permitem o gerenciamento agrícola baseado na variabilidade espacial e temporal da unidade de produção, visando o aumento do retorno econômico e, ao mesmo tempo, a redução do impacto ao ambiente (BRASIL, 2009).

No processo de aplicação da AP na irrigação, o conhecimento da variabilidade espacial dos atributos físico-hídricos do solo contribui para o manejo do solo e da água adequado a cada situação local (BASSOI et al., 2019), pois com base nesses atributos, é possível definir zonas de manejo para o monitoramento da umidade na camada de solo, na qual o sistema radicular das culturas está presente (NASCIMENTO et al., 2014; OLDONI et al., 2018), configurando o primeiro passo para realizar uma irrigação em taxa variável. Dentro do estudo dos atributos físico-hídricos do solo, o conteúdo de água é normalmente variável de acordo com a textura do solo, e o seu conhecimento é de fundamental importância para o correto manejo da água na irrigação (MICHELON, 2005). Além da determinação direta dos parâmetros físico-hídricos do solo, a condutividade elétrica aparente (CEa) é outra variável que pode ser utilizada para a estimativa da variação espaço-temporal da água no solo e assim, também permite a definição de zonas de manejo com base na umidade armazenada no perfil do solo (IBRAHIM & HUGGINS, 2011).

OBJETIVOS

Este trabalho teve como objetivo identificar a variabilidade espacial da água disponível (AD) e da condutividade elétrica aparente (CEa) no solo de um talhão agrícola irrigado por pivô central e propor estratégias de irrigação em taxa variável. Essa prática está em sinergia com os processos agronômicos sustentáveis, pois é uma maneira de melhorar a alocação de recursos de produção, priorizando a sua aplicação em locais com maior assertividade.

MATERIAL E MÉTODOS

O estudo foi conduzido em um talhão agrícola irrigado por pivô central localizado na área didático experimental do Colégio Politécnico da Universidade Federal de Santa Maria (UFSM), na cidade de Santa Maria - RS. A área está situada nas coordenadas geográficas Latitude 29º72'37" Sul e Longitude de 53º74'97" Oeste e altitude de, aproximadamente, 108 metros ao nível médio dos mares. O clima da região é o Cfa, subtropical úmido e com verões quentes, segundo a classificação de Köppen. A área total irrigada pelo pivô central (Figura 1A) é de 8,8 ha e apresenta um desnível de 15 m. O pivô possui duas torres, com vãos de 54 metros e um balanço de 25 metros, obtendo-se 133 metros de raio, além um aspersor no final da linha lateral com alcance de até 25 metros, totalizando um raio irrigado de 167 metros, que será a área analisada. O trabalho foi realizado em dois passos principais, que consistiram na determinação da CEa do solo com o uso de um equipamento VERIS U3 (Figura 1B) e na determinação da AD do solo a partir de coletas de solo (Figura 1C).



FIGURA 1. Pivô da área experimental irrigada do Colégio Politécnico da UFSM (A), implemento de condutividade elétrica Veris U3 (B) e coleta dos anéis volumétricos na camada de 0-20 de profundidade (C).

Para a mensuração da CEa, foi utilizado o equipamento VERIS U3 acoplado em um trator agrícola. Com estas ferramentas, realizou-se o trajeto no campo com espaçamento entre passadas de 14 m (Figura 2), coletando os dados na camada de 0 a 20 cm do solo. Após a coleta dos dados, foi realizada a filtragem e posteriormente a interpolação por krigagem ordinária dos pontos, visando a obtenção do mapa de variabilidade de CEa, expresso em mS/m.

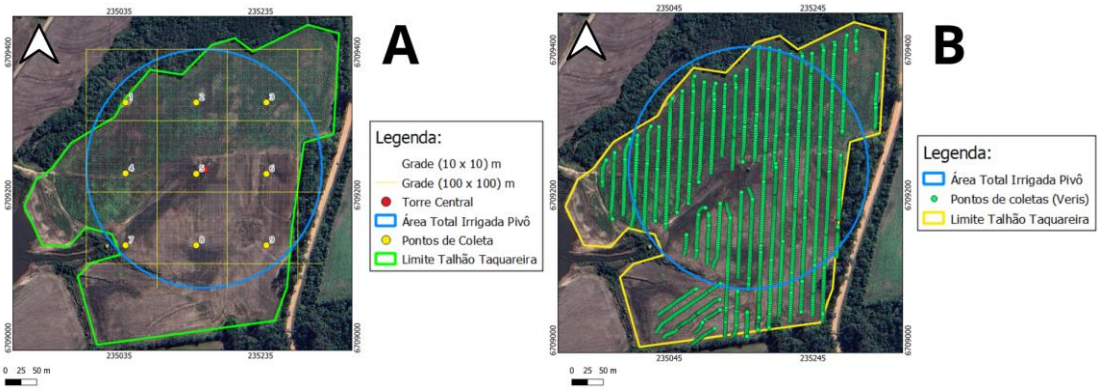


FIGURA 2. Pontos de amostragem para a determinação da AD no solo (A). Percurso realizado pelo equipamento VERIS U3 para a determinação da CEa do solo (B).

A segunda etapa do trabalho consistiu na determinação da AD na porção mediana da camada de 0 a 20 cm do solo. Para isso, na área de abrangência do pivô central, foram definidos 9 pontos de coleta (Figura 3), e em cada ponto foram coletadas três amostras de solo com estrutura preservada, com o auxílio de um extrator e de um cilindro de metal. Além disso, em cada ponto de coleta foram retiradas amostras de solo deformadas contendo aproximadamente 0,5 kg.

As amostras de solo foram levadas ao laboratório para a determinação dos parâmetros físico-hídricos. No laboratório, as amostras com estrutura preservada foram saturadas e colocadas na mesa de coluna de areia, nas tensões de -0,001, -0,004 e -0,01 MPa por 48 horas, respectivamente. Posteriormente, as amostras foram colocadas no aparelho extrator de água elaborado por Richards (RICHARDS, 1949), onde foi obtida a umidade do solo nos potenciais de -0,033 e -0,10 MPa. Na sequência, as amostras foram colocadas na estufa a 105 ºC para secagem até se observar massa constante. A umidade das amostras de solo nos potenciais de -0,5 e -1,5 MPa foi determinada através de psicometria, utilizando câmaras de um potenciômetro de ponto de orvalho, WP4 "dewpoint potentiometer" (DECAGON, 2000). Para essa avaliação, utilizaram-se de cinco a sete sub-amostras de solo com estrutura deformada, as quais foram secas ao ar, umedecidas com água através de um borrifador, pesadas e levadas o WP4, para fazer a leitura do potencial que a amostra se encontrava.

Após isso, as amostras foram levadas para estufa para secagem até atingir massa constante. A diferença entre as duas pesagens correspondeu ao conteúdo de água do solo no potencial determinado pelo WP4.

Relacionando-se o potencial determinado no WP4 para cada sub-amostra com a sua respectiva umidade, traçou-se uma curva com escala logarítmica, da qual foram retirados os valores de umidade do solo nos potenciais de -0,5 e -1,5 MPa. A AD foi determinada para a camada de 0-20 cm do solo e a lâmina de água foi convertida para mm, por meio da Equação 1:

$$AD = 1000 (\theta CC - \theta PMP) Zr \quad (1)$$

Em que: θCC - umidade na capacidade de campo; θPMP - umidade no ponto de murcha permanente; e Zr - comprimento considerado da zona radicular.

Na determinação da θCC, usou-se a umidade a -0,01 MPa para pontos com textura arenosa e a -0,033 MPa para as demais classes texturais, levando em consideração a classificação textural observada na Figura 3, e a θPMP foi determinada a -1,5 MPa para todas as classes texturais. Após a obtenção dos valores da CAD, foi realizada interpolação IDW entre os valores para avaliar a variabilidade do atributo na área, utilizando o Software QGIS.

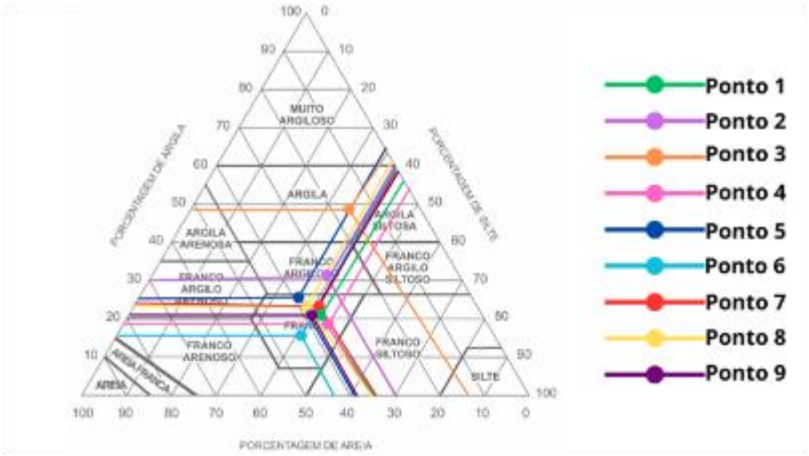


FIGURA 3. Classificação textural dos pontos de coleta de análise física do solo.

RESULTADOS E DISCUSSÃO

Houve variação na classificação textural dos pontos de amostragem realizados, devido às variações observadas nas frações de areia, silte e argila. Após a interpolação dos valores observados, foram identificadas três regiões com classes texturais distintas na área de abrangência do pivô (Figura 4), o que demonstra que há variabilidade nas características do solo dentro da mesma área, e a realização de manejos em taxa variável, incluindo a irrigação, pode ser uma alternativa para otimizar o uso de recursos no talhão.

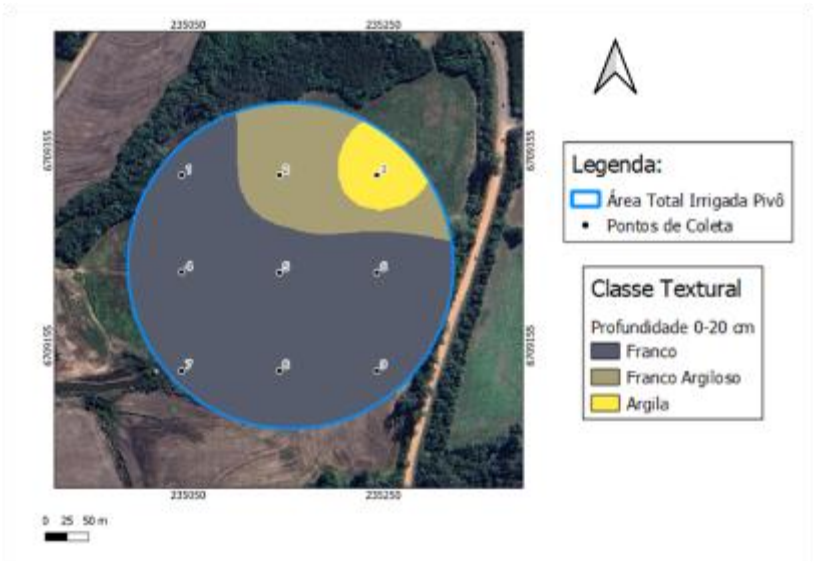


FIGURA 4. Variabilidade da classe textural dentro da área irrigada.

A variação na CEa do solo pode ser observada no mapa de variabilidade de CEa gerado (Figura 5). A variabilidade da CEa do solo pode explicar uma variedade de características e processos relacionados ao solo, incluindo o teor de umidade, salinidade, textura, distribuição de nutrientes e estrutura (JOHNSON et al., 2003; MOLIN & RABELLO, 2011). Neste estudo, comparando as Figuras 4 e 5, é possível observar que há uma tendência dos pontos com menor teor de argila apresentarem menor CEa, resultado semelhante ao encontrado por Guo et al. (2012).

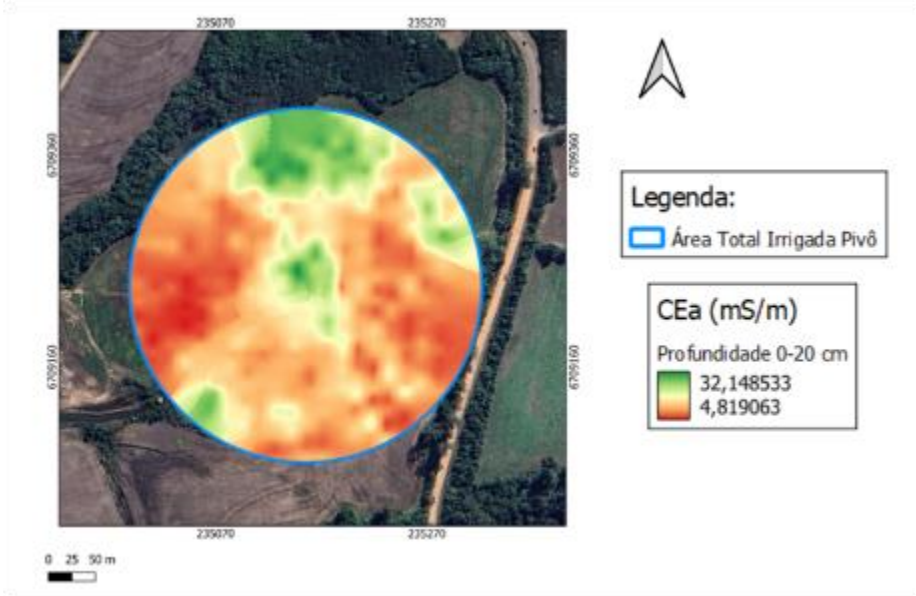


FIGURA 5. Variabilidade da condutividade elétrica aparente dentro da área irrigada.

A AD variou de 26,48 a 54,02 mm na camada de 0-20 cm do solo, o que representa uma variação de mais de 50% no resultado do menor para o maior valor de AD e confirma a relevância de se implementar um método de irrigação a taxa variável no talhão em estudo. Além disso, visualmente, comparando os mapas das Figuras 4, 5 e 6, é possível observar que os resultados encontrados neste estudo estão muito próximos ao que afirmam Haghverdi et al., 2015, que os dados de CEa possuem uma boa correlação com os atributos físico-hídricos do solo e por isso, podem ser utilizados como dados auxiliares na definição de zonas de manejo para a irrigação em taxa variável.

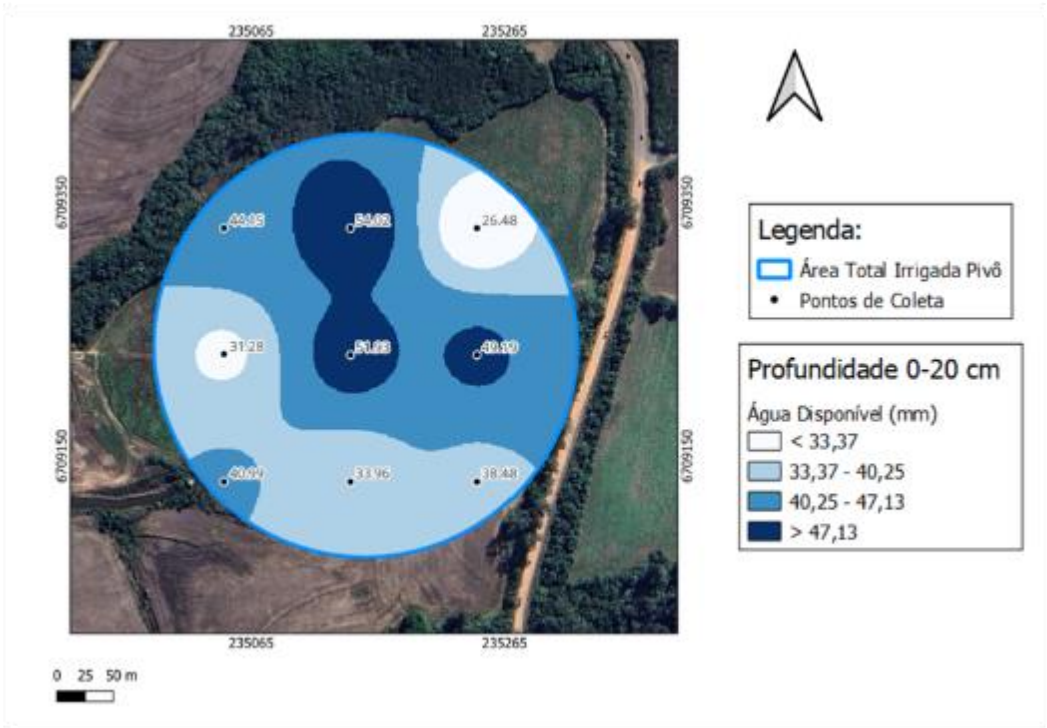


FIGURA 6. Variabilidade da capacidade da água disponível dentro da área irrigada.

Embora na maior parte da área as regiões com maior CEa tenham coincidido com aquelas em que houve maior AD, é necessário fazer algumas críticas à metodologia utilizada, por exemplo, na distribuição dos pontos de coleta para análise físico-hídrica do solo, na qual a área total irrigada foi dividida em 9 subáreas, que representaram 0,98 hectares cada. Após criar os mapas de variabilidade da AD, foi observado que alguns pontos de amostragem, a exemplo o ponto de número 3 (Figura 4), ficou localizado em uma pequena região de baixa CEa, o que desviou a interpolação IDW para uma menor média de AD. Neste sentido, o ideal era que primeiro fosse realizada a avaliação de CEa e, após o processamento do mapa de variabilidade, fossem definidos pontos de coleta direcionados pelas zonas de CEa, que dariam origem à Figura 6, tornando, dessa forma, o mapa de AD mais semelhante ao de CEa.

Tendo em vista os benefícios econômicos, ambientais e sociais que são promovidos pela implantação do sistema de irrigação em taxa variável, os fabricantes de pivôs vêm incrementando os níveis de tecnologia embarcada. Essas tecnologias funcionam por meio de três componentes principais, que são as informações, os sistemas de suporte a decisões e os equipamentos de aplicação (GRISSO et al., 2009). As informações podem ser coletadas de diferentes formas, como por exemplo, pela utilização de sensoriamento remoto (imagens NDVI e NDRE) ou pela coleta de dados de CEa, como foi feito neste trabalho. Em síntese, quanto maior o número de camadas de informações forem utilizadas, mais assertivo será a tomada de decisão nas definições de zonas de manejo de irrigação. Os sistemas de suporte a decisões variam de acordo com as informações que foram coletadas, e é a partir disso que será definido a forma como serão delimitadas as zonas de manejo para realizar a irrigação em taxa variável. De acordo com os equipamentos de aplicação que estão presentes na propriedade, pode ser definido o nível de tecnologia que será empregado nesta etapa, por isso, . Em alguns casos, ocorre o fornecimento de mapas de prescrição para a irrigação, e a partir desses mapas, constroem-se sistemas de controle que modificam a velocidade de deslocamento do pivô para alterar as taxas de aplicação em cada setor ou zona, ou pode ser variada a taxa de abertura das válvulas solenóides elétricas (GRISSO et al., 2009). No caso deste estudo, levando em consideração a tecnologia embarcada no pivô central utilizado, é possível fazer alterações nas taxas de irrigação por setores, conforme o proposto pela Figura 7. Neste caso, foi proposto duas zonas de manejo de irrigação, uma que apresentou maior quantidade de AD e maior valor de CEa. Em outros casos, é

possível dividir a área irrigada do pivô central em mais setores, a depender da variabilidade da disponibilidade de água no solo, classe textural ou condutividade elétrica aparente do solo.

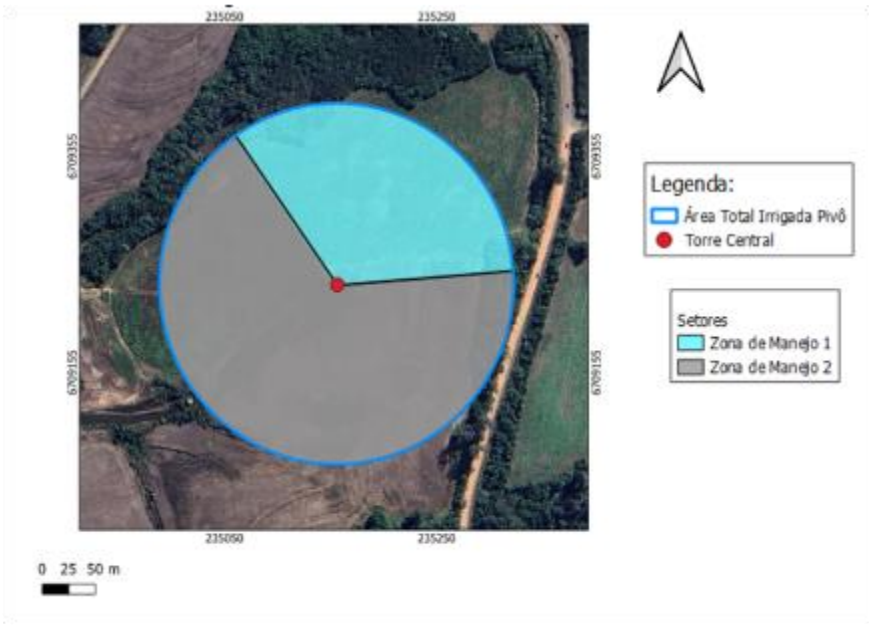


FIGURA 7. Definição de irrigação em taxa variável por setores, de acordo com a variabilidade da AD e da CEa no talhão agrícola avaliado.

Por outro lado, caso o pivô central utilizado permitisse a realização de irrigação em taxa variável por meio da variação na abertura de válvulas solenóides elétricas, poderia ser elaborado um mapa de prescrição para irrigação, levando em consideração a variabilidade de AD, apresentada na Figura 6. Realizando uma irrigação variável por zonas. Neste caso, a precisão e a otimização no uso da água iriam aumentar, o que evidencia que é possível utilizar diferentes formas de irrigação em taxa variável e ainda, que o emprego de menor ou maior grau de tecnologias no equipamento de irrigação, pode resultar em maior precisão e otimização no uso de recursos. Essa maior precisão pode ser avaliada in loco principalmente através de um comparativo entre zonas, realizando análises das características do solo e do desenvolvimento das plantas.

CONCLUSÃO

A área irrigada avaliada apresenta variabilidade espacial na AD e na CEa, a qual está fortemente relacionada, também, com a variabilidade de textura presente na área. A variabilidade da AD e da CEa está presente no talhão de tal forma que seria possível realizar a irrigação em taxa variável por meio da definição de setores ou zonas de taxa variável de lâmina de irrigação, em que cada setor/zona terá uma recomendação de lâmina diferente. O nível de tecnologia empregado no pivô central define o maior ou menor grau de precisão e de economia de recursos, no entanto, muitas vezes é limitado pelo alto custo de implantação, o que acaba sendo um dos maiores desafios para a empregabilidade da irrigação em taxa variável. Por fim, conclui-se que mesmo em talhões considerados pequenos, a variabilidade em diferentes atributos pode estar presente, e a prática de manejo localizado pode acarretar em maior otimização no uso de recursos hídricos e energia na agricultura.

REFERÊNCIAS

BASSOI, L. H. et al. Agricultura de precisão e agricultura digital. **TECCOGS - Revista Digital de Tecnologias Cognitivas**, n. 20, jul./dez. 2019, p. 17-36.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. **Agricultura de precisão / Ministério da Agricultura, Pecuária e Abastecimento.** Secretaria de Desenvolvimento Agropecuário e Cooperativismo. Brasília : Mapa/ACS, 2009, 31 p.

DECAGON DEVICES. Operator´s manual version 1.3 WP4 dewpointmeter. USA, **Decagon devices**, 2000. 70 p.

GRISSO, R.; ALLEY, M.; MCCLELLAN, P.; BRANN, D.; and DONOHUE, S. Precision farming: A comprehensive approach. Virginia Cooperative Extension. **Virginia Tech Publication**, p. 442-500, 2009.

GUO, W., MAAS, S. J, BRONSON, K. F. Relationship between cotton yeld and soil electrical conductivity, topography, and Landsat imagery. **Precision Agric.** 13 (6), p. 678-692, 2012.

HAGHVERDI, A. et al. Perspectives on delineating management zones for variable rate irrigation. **Computers and Electronics in Agriculture**, n. 117, p. 154-167, 2015.

IBRAHIM, H. M.; HUGGINS, D. R. Spatio-temporal patterns of soil water storage under dryland agriculture at the watershed scale. **Journal of Hydrology**, n. 404, p. 186-197, 2011.

JOHNSON, C.K., MORTENSEN, D.A., WIENHOLD, B.J., SHANAHAN, J.F., DORAN, J.W. Site-specific management zones based upon soil electrical conductivity in a semiarid cropping system. **Agron.** J. 95, 303-315, 2003.

MICHELON, C. J. **Qualidade física de solos irrigados do Rio Grande do Sul e do Brasil Central.** 2005. 92 p. Dissertação (Mestrado em Ciência do Solo) - Programa de Pós-Graduação em Ciência do Solo, Universidade Federal de Santa Maria, Santa Maria. Disponível em: <CLEUDSON MICHELON.pdf (ufsm.br)> . Acesso em: 25 mar. 2024.

MOLIN, J. P.; RABELLO, L. M. Estudos sobre a mensuração da condutividade elétrica do solo. **Engenharia na Agricultura**, v. 31, n. 1, p. 90-101. 2011.

NASCIMENTO, P. S. ; BASSOI, L. H.; SILVA, J. A.; COSTA, B. R. S. Zonas homogêneas de atributos do solo para o manejo de irrigação em pomar de videira. **Revista Brasileira de Ciência do Solo**, v. 38, p. 1101-1113, 2014.

OLDONI, H. et al. Delineamento de zonas de manejo de irrigação em vinhedo com base na granulometria do solo. **In: Congresso Brasileiro de Agricultura de Precisão**, 2018, Curitiba. Construção dos dados na era da digitalização agrícola. Curitiba: AsBraAP, 2018. p. 52-58.

RICHARDS, L. A. Methods of measuring moisture tension. **Soil science**, Madison, v. 58, 1949, p.95-112.

SETTI, A. A. et al. **Introdução ao gerenciamento de recursos hídricos.** 2 ed. Brasília: Agência Nacional de Energia Elétrica, Superintendência de Estudos e Informações Hidrológicas, 2001. 207 p.

AVALIAÇÃO DO DESEMPENHO DE MODELO *DEEP LEARNING* PARA O RECONHECIMENTO DE PLANTAS DANINHAS NA CULTURA DA SOJA E DO MILHO

Estéfani Sulzbach [1]; Ismael Scheeren [3]; Inácio Barbosa [1]; Aldo Merotto Jr [2]; Catarine Markus [2]
[1]Estudante de doutorado . Porto Alegre, RS, Brasil. Universidade Federal do Rio Grande do Sul; [2]Docente. Porto Alegre, RS, Brasil. Universidade Federal do Rio Grande do Sul; [3]Diretor. Porto Alegre, RS, Brasil. Accore - Engenharia de sistemas

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
A aplicação de herbicidas em área total é uma prática recorrente e normalmente as plantas daninhas têm distribuição desuniforme na lavoura. Assim, a aplicação em área total faz com que o herbicida seja aplicado em locais sem a presença dessas espécies. O uso de algoritmos para detecção de plantas daninhas em tempo real pode ser uma alternativa para aplicação localizada de herbicidas. Dessa forma, o objetivo do presente estudo foi avaliar o desempenho da rede neural YOLOv8 para detecção de plantas daninhas nas culturas da soja (*Glycine max*) e milho (*Zea mays*). As imagens coletadas a campo foram anotadas manualmente e treinadas com a rede neural YOLOv8. As classes utilizadas para treinamento foram soja, milho, caruru (*Amaranthus* spp), buva (*conyza* spp.), trapoeraba (*Commelina benghalensis*), folha larga e folha estreita. As métricas de Precisão, Recall e mAP50 foram utilizadas para avaliação do desempenho da rede neural. O *dataset* do presente estudo teve 2637 imagens e gerou um total de 12328 instâncias. O milho obteve o maior valor de Precisão, que correspondeu a 0,82, seguido pela buva com 0,74. A YOLOv8 obteve êxito em diferenciar plantas daninhas de milho e soja como também na diferenciação entre plantas daninhas. Esse trabalho é pioneiro no Brasil para o reconhecimento de plantas daninhas pela utilização da YOLOv8. Ainda, esse foi o primeiro estudo que gerou um único modelo com *dataset* de soja e milho com diversidade de plantas daninhas.

PALAVRAS-CHAVE: Inteligência artificial; Aplicação localizada de herbicidas; You Only Look Once

ABSTRACT
The standard whole-field herbicide application (blanket spraying) is a recurring weed management and normally weeds have an uneven distribution in the crop. Thus, application over a total area means that the herbicide is applied in places without the presence of these species. The use of algorithms for real-time weed detection can be an alternative for localized application of herbicides. Therefore, the objective of the present study was to evaluate the performance of the YOLOv8 neural network for detecting weeds in soybean (*Glycine max*) and corn (*Zea mays*) crops. The images collected in the field were manually annotated and trained with the YOLOv8 neural network. The classes used for training were soybean, corn, pigweed (*Amaranthus* spp), horseweed (*Conyza* spp.), benghal dayflower (*Commelina benghalensis*), broadleaf and narrowleaf. The Precision, Recall and mAP50 metrics were used to evaluate the performance of the neural network. The dataset of the present study had 2637 images and generated a total of 12328 instances. Corn obtained the highest Accuracy value, which corresponded to 0.82, followed by horseweed with 0.74. YOLOv8 was successful in differentiating corn and soybean weeds as well as differentiating between weeds. This work is pioneering in Brazil for the recognition of weeds using YOLOv8. Furthermore, this was the first study that generated a single model with a soybean and corn dataset with weed diversity.

KEYWORDS: Artificial intelligence; site-specific herbicides application; You Only Look Once

INTRODUÇÃO

O uso de herbicidas para o controle de plantas daninhas é a principal forma de manejo utilizada em áreas agrícolas. No entanto, esse manejo apresenta alto custo e por vezes as aplicações ocorrem em locais sem a presença de plantas infestantes. Ainda, esse manejo não garante o controle de todas as espécies de plantas daninhas devido aos casos de resistência a herbicidas. O desenvolvimento de técnicas em agricultura de precisão sugere estratégias de alta tecnologia associada à Inteligência Artificial (IA), que abrangem *machine learning* e *deep learning* e possibilitam o manejo localizado de plantas daninhas (PARTEL; CHARAN KAKARLA; AMPATZIDIS, 2019). Essas técnicas abrem caminhos para o manejo localizado de plantas daninhas. Cabe salientar que a aplicação localizada de herbicidas pode ser uma estratégia importante para o manejo de espécies de plantas daninhas de difícil controle e resistentes aos herbicidas (GHATREHSAMANI et al., 2023). Uma vez que é possível realizar a aplicação localizada de herbicidas alternativos com mecanismos de ação diferentes. Esse manejo pode atrasar a seleção e evolução de novos casos de resistência (EVANS et al., 2015). O fator chave para aplicação localizada de herbicidas é a obtenção de acuraria na detecção de plantas daninhas, sendo elas muitas vezes dispersas em lavouras; e sobrepostas entre culturas e diferentes espécies de plantas daninhas (GERHARDS et al., 2022).

Recentemente, a visão computacional combinada com técnicas de aprendizagem profunda (*deep learning*) cria uma ferramenta importante para detecção e classificação de objetos em tempo real. A arquitetura da rede neural YOLO (*You Only Look Once*) desenvolvida por Redmon em 2016, propõe um algoritmo de detecção de objetos que consiste em treinar uma DCNN (rede neural convolucional profunda), que prediz a classe e a posição precisa dos objetos em imagens e/ou vídeos. Além disso, esse algoritmo apresenta vantagens na detecção de objetos sobrepostos, alta assertividade e velocidade de processamento. Essas características são fundamentais para a detecção de plantas daninhas e aplicação de herbicidas em tempo real. No entanto, a YOLO é um algoritmo de treinamento supervisionado, isso faz com que seja necessária a etapa de anotação de dados para utilizá-los no treinamento da rede. No mundo, existem bancos de dados disponíveis como "public weeds" (Agumented Startups), "CottonWeedDet12" (DANG et al., 2023) e "corn field" (JIANG et al., 2020), Contudo, esses bancos não abrangem algumas das plantas daninhas importantes para do Brasil ou apresentam baixa complexidade, o que distancia das condições encontradas na lavouras. Além disso, ainda não foram verificados estudos utilizando a última versão da YOLOv8 para detecção de plantas daninhas nas culturas da soja e do milho. Dessa forma, o objetivo do presente estudo foi avaliar o desempenho da rede neural YOLOv8 para detecção de plantas daninhas nas culturas da soja e milho.

OBJETIVOS

O objetivo do presente estudo foi avaliar o desempenho da rede neural YOLOv8 para detecção de plantas daninhas nas culturas da soja e milho.

MATERIAL E MÉTODOS

O banco de imagens total foi composto por mais de 5.000 imagens RGB (vermelho, verde e azul) para detecção de soja, milho e plantas daninhas. As imagens foram obtidas em áreas agrícolas de Eldorado do Sul (30° 5' 9" S, 51° 37' 5" O), Fazenda Vilanova (29° 35' 34" S, 51° 49' 9" O), Selbach (28° 37' 34" S, 52° 57' 12" O) e Porto Alegre (30º 01' 59" S, 51º 13' 48" O), no estado do Rio Grande do Sul, Brasil. A obtenção de fotos foi realizada entre o período de novembro a março de 2021 a 2024 nas áreas de soja, e entre 2023 e 2024 nas áreas de milho. As imagens foram obtidas com câmera Sony (SONY Corporation, Minato, Tokyo, Japan) a ~1,0 metros de altura do solo. As quatro áreas selecionadas para coleta de imagens apresentam infestação natural das principais plantas daninhas relacionadas a cultura da soja e do milho. O banco de imagens foi composto principalmente pelas espécies de caruru (*Amaranthus* spp.), buva (*conyza* spp.), trapoeraba (*Commelina benghalensis)*, corriola (*Ipomoea* spp.), poaia branca (*Richardia brasiliensis*), picão-preto (*Bidens pilosa*),

guanxuma (*Sida rhombifolia*), leiteiro (*Euphorbia heterophylla*), papuã (*Brachiaria plantaginea*), capim-pé-de-galinha (*E. indica*) e capim-colchão (*Digitaria horizontalis*). No entanto, outras plantas daninhas em menor frequência nas áreas também foram registradas. Para a soja foram obtidas imagens nos estádios fenológicos de VC (cotiledonar) a R3 (início da formação do legume), para o milho entre VE (emergência) a V6 (sexta folha desenvolvida). O banco de dados utilizado apresentava complexidade e robustez, devido a diversidade de espécies de plantas daninhas, tamanho de plantas, condições de luminosidade do ambiente (períodos com alta e baixa luminosidade), classe de solo (coletas em diferentes regiões do estado) e quantidade de cobertura do solo, sendo que foram capturadas imagens em áreas de plantio convencional e plantio direto (com diferentes níveis de palhada).

A rede neural selecionada para o reconhecimento de plantas daninhas em ambas as culturas foi a YOLO devido a sua acurácia e velocidade em detectar objetos em tempo real. A última versão da YOLO foi lançada em 2023 e corresponde a versão 8 (YOLOv8), a qual foi escolhida para o treinamento do presente estudo. Como a YOLO é uma arquitetura de aprendizado supervisionado foi necessária a anotação das imagens coletadas a campo para o treinamento da rede. A anotação das imagens foi realizada através da criação de caixas delimitadoras (*bounding boxes*) no entorno de cada planta das 2637 imagens, que foram selecionadas do banco de dados total para compor o *dataset*. Na anotação foi atribuída uma classe representativa para cada planta alvo, o que gerou as instâncias de cada classe. As classes utilizadas foram soja, milho, caruru, buva, trapoeraba, dicotiledôneas (folhas largas) e monocotiledôneas (folhas estreitas). Cabe salientar que as plantas sobrepostas também foram delimitadas, nesse caso considerou-se somente as partes que realmente pertenciam a planta alvo, de forma a não incluir outras plantas dentro da *bounding box*, para evitar os falsos-negativos (FN) pela rede neural. As anotações das imagens foram realizadas manualmente com o software livre, de interface gráfica denominado LabelImag (https://github.com/heartexlabs/labelImg) (Figura 1).



Figura 1. LabelImag utilizado para marcações de imagens.

O *dataset* final foi dividido 80% para imagens de treinamento, 10% para teste e 10% para validação. Assim, 2073; 281; e 283 imagens foram utilizadas para treinamento, teste e validação, respectivamente. A avaliação do desempenho do algoritmo foi realizada através da obtenção das métricas de Precisão, Recall e a média da AP (mAP). A Precisão relaciona o verdadeiro-positivo (VP) e o falso-positivo (FP), e indica dentre todos os marcados qual percentual realmente é positivo. O Recall relaciona os VP e os FN, ou seja, indica dentre as marcações positivas qual o percentual que está sendo identificado corretamente. Já o mAP é o valor da média calculado a partir do valor da média das previsões de todas as classes. Foi utilizado o limite de interseção da união (IoU) entre as

plantas anotadas e as caixas delimitadoras previstas de 0,5 (50%) (HENDERSON; FERRARI, 2017), a partir disso, foram determinadas as detecções consideradas como VP e FP. Cabe salientar que o IoU é definido como a sobreposição entre as caixas delimitadoras oriundas da anotação manual e a caixa delimitadora prevista pela YOLOv8, dividida pela área total de cada caixa delimitadora. Os valores de IoU maiores ou iguais a 0,5 foram considerados VP, e valores menores que 0,5 foram considerados previsões de FP (HENDERSON; e FERRARI, 2017). Ainda, para verificação do desempenho da YOLOv8 foi gerada matriz de confusão para observar as predições feitas pela rede neural versus a predição esperada. A precisão média para cada classe foi determinada através da curva de Precisão-Recall para todas as classes (HENDERSON; FERRARI, 2017).

RESULTADOS E DISCUSSÃO

O *dataset* do presente estudo teve 2637 imagens e gerou um total de 12328 instâncias (Tabela 1). As instâncias foram geradas a partir da diversidade de espécies, tamanhos e formas presentes no *dataset*. O desempenho geral do modelo foi de 0,69 (mAP50) e se aproxima dos resultados verificados em estudos realizados com bancos de dados restritos a poucas classes e com baixa diversidade de cenários (BARNHART et al., 2022; PÉREZ-PORRAS et al., 2023). Em um dos estudos foram consideradas somente duas classes, a espécie *A. palmeri* e a cultura da soja, e foi utilizada a rede YOLOv5, a qual apresentou mAP50 de 0,77 (BARNHART et al., 2022). Para o reconhecimento das classes da planta daninha *Papaver rhoeas* e da cultura do trigo (*Triticum* spp.) a YOLOv5 obteve mAP50 de 0,76. Recentemente, um estudo demonstrou mAP50 de 0,87 com a YOLOv8 para reconhecimento de quatro espécies de plantas daninhas com a cultura do milho (HASAN et al., 2024). O desempenho foi superior ao verificado no presente estudo, no entanto, ainda com número restrito de plantas daninhas. Salienta-se que normalmente quanto maior a diversidade do *dataset* e número de classes, maior é a complexidade do *dataset* e maior a dificuldade para o treinamento da rede, no entanto, maior a proximidade para o reconhecimento em ambiente real.

Entre as diferentes classes utilizadas no presente trabalho verificou-se que o milho obteve o maior valor de Precisão, que correspondeu a 0,82, seguido pela buva com 0,74, folha larga com 0,71 e caruru com 0,70 (Tabela 1 e Figura 2). As demais classes ficaram abaixo de 0,70, sendo que a classe folha estreita apresentou o menor valor de Precisão, que correspondeu a 0,56 (Tabela 1 e Figura 2). Cabe salientar que na anotação manual foi constatada maior complexidade de tamanhos, formas e morfologia de plantas para a classe folha estreita. A melhoria dos parâmetros pode ser obtida com o aumento do *dataset* para essa classe. Um estudo com a YOLOv4 utilizou um *dataset* com >3500 imagens e 13 classes de espécies de plantas daninhas. O desempenho da rede foi satisfatório, com mAP50 de 0,93 (MWITTA; RAIS; PROSTKO, 2024). Destaca-se que no trabalho as imagens apresentavam plantas daninhas apenas em estádios iniciais, ou seja, foi verificado menor número de variações de formas e tamanhos, diferente do que foi explorado no presente estudo. Ainda, explorar um *dataset* com plantas daninhas representativas para cada região e/ou país de estudo pode ser uma ferramenta importante para futuramente realizar o controle localizado de espécies com resistência a herbicidas.

Os valores encontrados para Recall ficaram entre 0,74 e 0,61, sendo que o maior valor foi verificado para buva, seguido da soja com 0,73 (Tabela 1). As demais classes apresentaram valores abaixo de 0,70. O Recall é uma métrica que indica o percentual de predições que estão sendo identificadas corretamente. Os valores de Recall verificados no presente estudo são similares ao que já foi verificado com a YOLOv8, em área de pomar com o uso de apenas uma classe para plantas daninhas denominada "weeds" (SAMPURNO et al., 2024). No entanto, outro estudo obteve valores acima de 0,90 para diferentes variantes da YOLOv8 (SPORTELLI et al., 2023). O *dataset* utilizado foi uma base de dados públicos com diversas plantas, no entanto, no trabalho não houve distinção de classes dentro das plantas daninhas O uso de apenas uma classe é um fator que evita a complexidade e desbalanceamento de dados. Isso beneficia a obtenção de Recall alto, diferente do que foi realizado

no presente estudo, que contou com sete classes e com diferente número de instancias por classe (Tabela 1). O balanceamento de dados entre classes pode ser obtido através de técnicas como o *data augmentation* a partir da geração de imagens artificiais (RUIGROK; VAN HENTEN; KOOTSTRA, 2023). A diversidade de cenários e de espécies de plantas no *dataset* pode ser beneficiada com o uso dessa técnica, que será uma das estratégias utilizadas nas próximas etapas deste estudo.

Tabela 1. Métricas para avaliar o desempenho da rede neural YOLOv8.

Classes	Instâncias	Precisão	Recall	mAP50
Soja	2316	0,68	0,73	0,73
Milho	225	0,82	0,63	0,74
Caruru	1338	0,70	0,68	0,73
Buva	485	0,74	0,74	0,66
Trapoeraba	323	0,61	0,61	0,67
Folha Larga	4751	0,71	0,62	0,69
Folha estreita	2890	0,56	0,61	0,59
Todas	12328	0,68	0,64	0,69

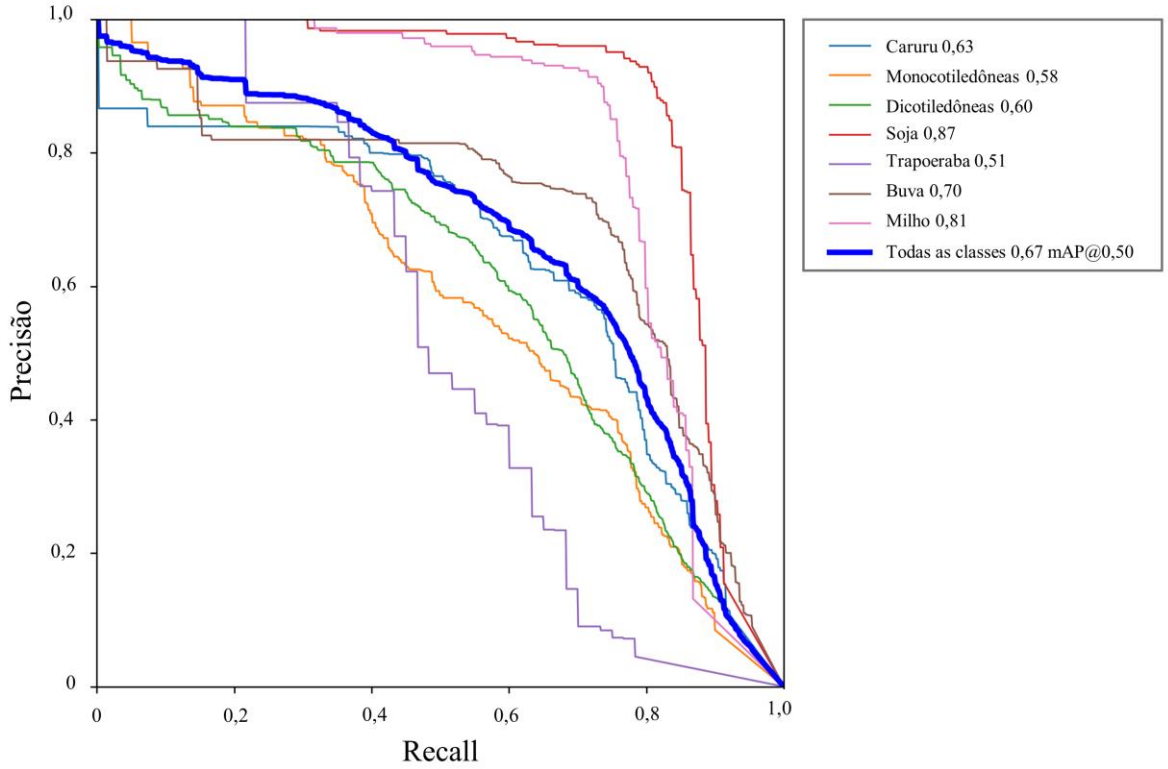


Figura 2. Curva de precisão-recall para YOLOv8. A linha azul escuro representa o mAP50 calculado a partir dos dados de teste.

Uma matriz de confusão contém informações sobre as classificações de objetos reais e esperadas de um sistema de categorização. A linha diagonal indica as predições feitas pela rede neural como VP (Figura 3). Nessa linha diagonal, é possível verificar a quantidade de predições corretas dentro de cada classe de acordo com o esperado. A classe folha larga apresentou o maior número (3191) de

predições corretas. Seguido pelas classes de folha estreita (2015) e soja (1869). As demais classes apresentaram predições assertivas abaixo de 1000. Possivelmente esses números estejam atrelados ao número de instâncias para cada uma das classes. Quanto maior o número de instâncias para cada classe, maior as chances de indicação de VP. A YOLOv8 testada mostrou indicações de VP para todas as classes utilizadas quando comparado aos FP e FN (Figura 3). Os FP estão indicados na última linha vertical e os FN na primeira linha horizontal (Figura 3). Os FP foram verificados principalmente para folha estreita (1636), folha larga (1630) e soja (954). Os maiores FN foram verificados para as mesmas classes, no entanto na seguinte ordem: folha larga (1245), folha estreita (836) e soja (419) (Figura 3). Contudo, é possível verificar que as três classes com maiores indicações de FN e FP foram as mesmas que apresentam um maior número de instâncias. Cabe salientar que o aumento do banco de dados para cada uma das classes é importante para o aumento do desempenho da rede neural nas detecções de plantas, no entanto, a complexidade de anotações verificada no presente trabalho contribuiu para essas indicações que futuramente serão ajustadas.

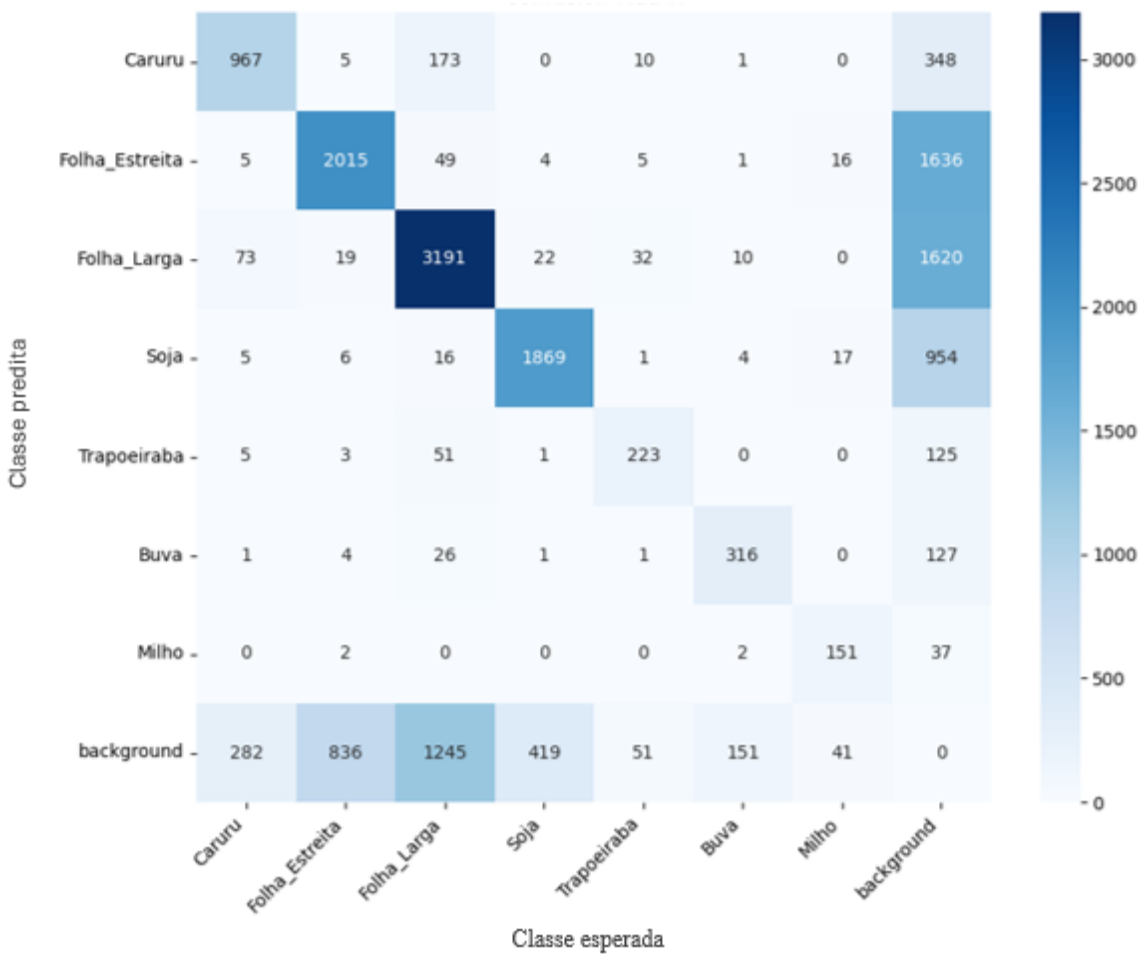


Figura 3. Matriz de confusão gerada a partir do treinamento da YOLOv8 com 2637 imagens. A matriz representa as classes preditas pela rede neural versus a classe esperada.

Na figura 4 é possível verificar as marcações de imagens realizadas pela rede neural após o treinamento. Essas imagens representam lavouras de soja (Figura 4-A) e milho (Figura 4-B). A partir dessas imagens é possível afirmar a boa capacidade da YOLOv8 em diferenciar plantas daninhas de culturas como também a diferenciação entre plantas daninhas. Isso abre espaço para diferenciações entre espécies de plantas daninhas com esse algoritmo. Para a soja é possível verificar a presença de plantas daninhas como a buva e caruru, ambas com casos de resistência a herbicidas no Brasil (HEAP, 2024). A correta detecção dessas infestantes no campo pode proporcionar futuramente o manejo de populações resistentes de forma localizada e com herbicidas alternativos. Para a cultura do milho,

conforme figura 4-B, foram verificadas marcações assertivas de milho e folha estreita na mesma imagem, sendo ambas gramíneas. Assim, é possível verificar que a similaridade entre plantas daninhas e culturas não limitou a detecção correta realizada pela YOLOv8. Desta forma, o *dataset* construído no presente estudo é representativo para soja e milho com abrangência de plantas daninhas de difícil controle no cenário da agricultura brasileira. Somado a capacidade da YOLOv8 diferenciar plantas a nível de gêneros, a rede realizou o reconhecimento de plantas sobrepostas, característica inerente da YOLO desde o seu lançamento (REDMON et al., 2016). Esses aspectos são fundamentais para utilização dessa ferramenta em sistemas embarcados e para aplicação localizada de herbicidas, que consistem nas próximas etapas de teste do presente trabalho.

A)



B)

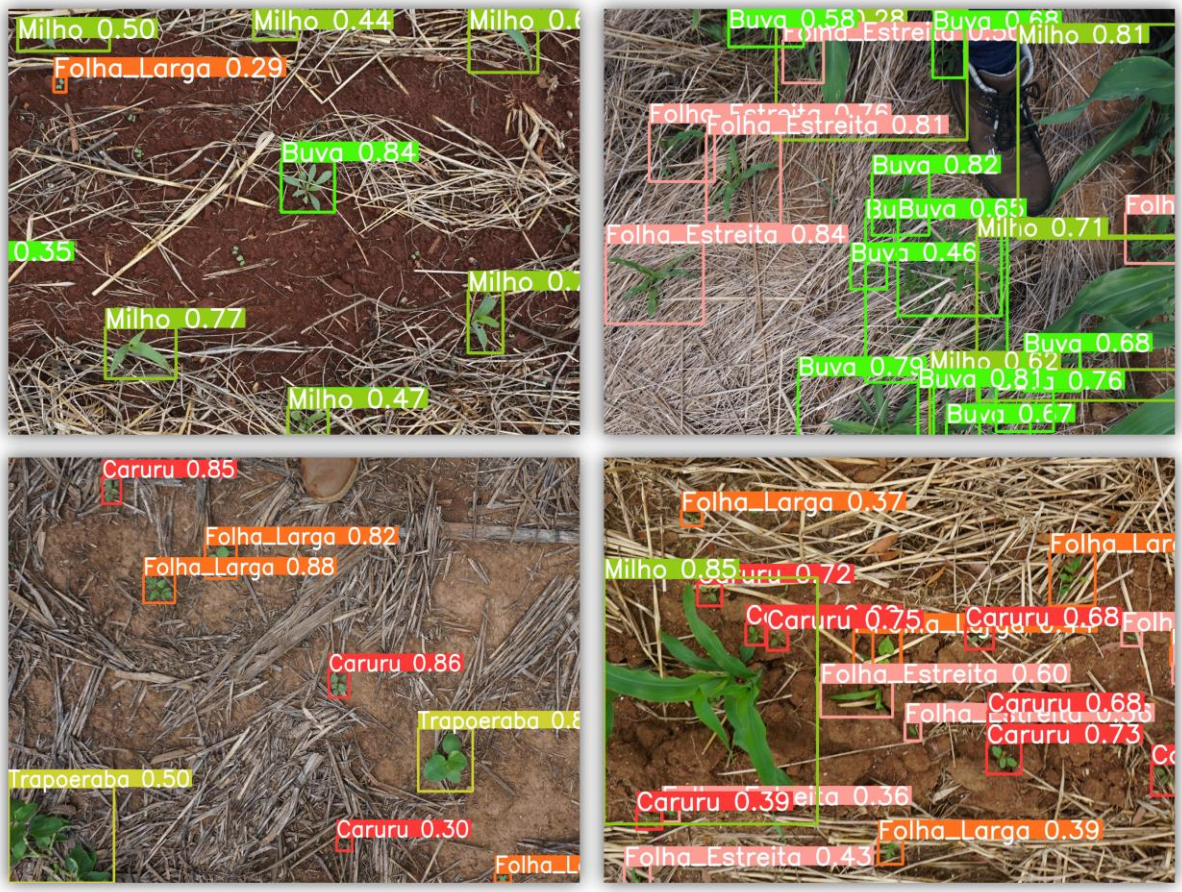


Figura 4. Imagens marcadas pela YOLOv8 após o treinamento. Em A e B estão representadas quatro imagens marcadas pela YOLOv8 em áreas de soja e milho, respectivamente.

CONCLUSÃO

Esse trabalho é pioneiro no Brasil para reconhecimento de plantas daninhas pela utilização de modelo *deep learning* com aYOLOv8 lançada em 2023. Ainda, esse foi o primeiro estudo que utilizou a YOLOv8 para detecção de plantas daninhas em áreas de soja e milho e ambas as culturas de forma conjunta em um único modelo. Isso aumenta a complexidade de espécies estudas e apresentou desempenho satisfatório, uma vez que se aproximou do desempenho verificado em outros estudos. O presente estudo gerou um *dataset* de imagens com uma complexidade de plantas daninhas em áreas de soja e milho, sendo que as espécies presentes são representativas para lavouras de ambas as culturas do Brasil. As anotações de imagens para modelos supervisionados representam um trabalho minucioso, com necessidade de profissionais capacitados para reconhecimento das espécies e com necessidade de tempo para anotações manuais. Considera-se que esses bancos de dados possam ser um diferencial para novos estudos e obtenção de métricas superiores. O modelo desse estudo será aperfeiçoado e posteriormente testado a campo para aplicação localizada de herbicidas em tempo real.

REFERÊNCIAS

AGUMENTED STARTUPS. Weeds Dataset 2021. Available online: https://universe.roboflow.com/augmented-startups/weeds-nxe1w >. Acesso em: 07 de março de 2024

BARNHART, I. H. et al. Use of open-source object detection algorithms to detect Palmer amaranth (Amaranthus palmeri) in soybean. **Weed Science**, v. 70, n. 6, p. 648-662, 2022.

DANG, F. et al. YOLOWeeds: A novel benchmark of YOLO object detectors for multi-class weed detection in cotton production systems. **Computers and Electronics in Agriculture**, v. 205, p. 107655, 2023.

EVANS, J. A. et al. Managing the evolution of herbicide resistance. **Pest Management Science**, v. 72, n. 1, p. 74-80, 2016.

GERHARDS, R. et al. Advances in site?specific weed management in agriculture-A review. **Weed Research**, v. 62, n. 2, p. 123-133, 2022.

GHATREHSAMANI, S. et al. Artificial Intelligence Tools and Techniques to Combat Herbicide Resistant Weeds-A Review. **Sustainability**, v. 15, n. 3, p. 1843, 2023.

HASAN, A. S. M. M. et al. Object-level benchmark for deep learning-based detection and classification of weed species. **Crop Protection**, v. 177, p. 106561, 2024.

HEAP, I. The international survey of herbicide resistant weeds. Disponível em: <http://www.weedscience.com>. Acesso em: 07 de março de 2024.

HENDERSON, P.; FERRARI, V. End-to-end training of object class detectors for mean average precision. **arXiv**, 16 mar. 2017. Disponível em: <http://arxiv.org/abs/1607.03476>. Acesso em: 30 mar. 2024

JIANG, H. et al. CNN feature based graph convolutional network for weed and crop recognition in smart farming. **Computers and Electronics in Agriculture**, v. 174, p. 105450, 2020.

MWITTA, C.; RAINS, G. C.; PROSTKO, E. Evaluation of Inference Performance of Deep Learning Models for Real-Time Weed Detection in an Embedded Computer. **Sensors**, v. 24, n. 2, p. 514, 2024.

PARTEL, V.; CHARAN KAKARLA, S.; AMPATZIDIS, Y. Development and evaluation of a low-cost and smart technology for precision weed management utilizing artificial intelligence. **Computers and Electronics in Agriculture**, v. 157, p. 339-350, 2019.

PÉREZ-PORRAS, F. J. et al. Early and on-ground image-based detection of poppy (*Papaver rhoeas*) in wheat using YOLO architectures. **Weed Science**, v. 71, n. 1, p. 50-58, 2023.

REDMON, J. et al. You Only Look Once: Unified, Real-Time Object Detection. **IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. Disponível em: <http://ieeexplore.ieee.org/document/7780460/>. Acesso em: 26 jul. 2023

RUIGROK, T.; VAN HENTEN, E. J.; KOOTSTRA, G. Improved generalization of a plant-detection model for precision weed control. **Computers and Electronics in Agriculture**, v. 204, p. 107554, 2023.

SAMPURNO, R. M. et al. Intrarow Uncut Weed Detection Using You-Only-Look-Once Instance Segmentation for Orchard Plantations. **Sensors**, v. 24, n. 3, p. 893, 2024.

SPORTELLI, M. et al. Evaluation of YOLO Object Detectors for Weed Detection in Different Turfgrass Scenarios. **Applied Sciences**, v. 13, n. 14, p. 8502, 2023.

DESEMPENHO DE VARIANTES DA YOLOv8 PARA DETECÇÃO DE PLANTAS DANINHAS EM TEMPO REAL NA CULTURA DA SOJA

Estéfani Sulzbach [1]; Ismael Scheeren [3]; Manuel Veras [4]; Paula Sinigaglia Angonese [1]; Catarine Markus [2]

[1]Estudante de doutorado. Porto Alegre, RS, Brasil. Universidade Federal do Rio Grande do Sul; [2]Docente. Porto Alegre, RS, Brasil. Universidade Federal do Rio Grande do Sul; [3]Diretor. Porto Alegre, RS, Brasil. Accore - Engenharia de sistemas; [4]Desenvolvedor de software. Porto Alegre, RS, Brasil. Accore - Engenharia de sistemas

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A rede neural YOLO (*You Only Look Once*) apresenta capacidade em detectar objetos em tempo real. O uso dessa rede neural para o reconhecimento de plantas daninhas pode ser uma ferramenta para aplicação localizada de herbicidas. Dessa forma, o objetivo do estudo foi avaliar o desempenho da YOLOv8 e suas variantes com e sem pré-treino e reduzir o tamanho dos parâmetros para melhorar a velocidade de processamento e possibilitar o reconhecimento de classes de plantas daninhas na cultura da soja. Inicialmente foram realizadas coletas de imagens em áreas de soja com as principais plantas daninhas associadas a cultura. Nove versões da YOLOv8 foram utilizadas para o treinamento. Desse total, cinco versões são originais da YOLOv8 (YOLOv8 Rede 1, YOLOv8 Rede 2, YOLOv8 Rede 3 e YOLOv8 Rede 4) e as outras quatro com otimização do número de parâmetros (YOLOv8 Rede 5, YOLOv8 Rede 6, YOLOv7 Rede 8 e YOLOv8 Rede 9). As redes sem pré-treino apresentaram desempenho similar quando comparado a redes pré-treinadas, ambas com valores de mAP50 entre 0,70 e 0,73. A redução no número de parâmetros das versões originais propostas pelos desenvolvedores da YOLOv8 não implica em redução do desempenho da rede. Contudo, a redução do número de parâmetros pode ser uma importante ferramenta para reduzir a complexidade e processamento de dados sem afetar o desempenho das arquiteturas e ser utilizada para o reconhecimento de plantas daninhas.

PALAVRAS-CHAVE: *Glycine max*; You Only Look Once; reconhecimento de plantas daninhas

ABSTRACT

The YOLO (You Only Look Once) neural network has the ability to detect objects in real time. The use of this neural network for weed recognition can be a tool for localized application of herbicides. Therefore, the objective of the study was to evaluate the performance of YOLOv8 and its variants with and without pre-training and reduce the size of the parameters to improve processing speed and enable the recognition of weed classes in soybean crops. Initially, images were collected in soybean areas with the main weeds associated with the crop. Nine versions of YOLOv8 were used for training. Of this total, five versions are original to YOLOv8 (YOLOv8 Network 1, YOLOv8 Network 2, YOLOv8 Network 3 and YOLOv8 Network 4) and the other four with optimization of the number of parameters (YOLOv8 Network 5, YOLOv8 Network 6, YOLOv7 Network 8 and YOLOv8 Network 9). Networks without pre-training showed similar performance when compared to pre-trained networks, both with mAP50 values between 0.70 and 0.73. The reduction in the number of parameters from the original versions proposed by the YOLOv8 developers does not imply a reduction in network performance. However, reducing the number of parameters can be an important tool to reduce complexity and data processing without affecting the performance of the architectures and be used for weed recognition.

KEYWORDS: *Glycine max*; You Only Look Once; weed recognition

INTRODUÇÃO

O reconhecimento de plantas daninhas pode ser realizado com o uso da inteligência artificial (IA) através do uso de redes neurais artificiais. Nos últimos anos, essa ferramenta apresentou grandes avanços também para o reconhecimento de plantas daninhas em tempo real (GERHARDS et al., 2022). Esses avanços são decorrentes da abordagem do *deep learning* no reconhecimento de imagens e vídeos (LECUN; BENGIO; HINTON, 2015; SIMONYAN; ZISSERMAN, 2014). Os modelos de *deep learning* são construídos com redes neurais artificiais multicamadas e podem ser treinados por meio de aprendizado supervisionado, semi-supervisionado ou não supervisionado (SCHMIDHUBER, 2015). O treinamento dessas redes neurais permite a classificação, segmentação ou detecção de objetos presentes em imagens. A arquitetura YOLO (*You Only Look Once*) é um algoritmo de detecção de objetos em imagens e vídeos que avançou nos últimos anos, devido à sua velocidade de processamento, detecção de objetos sobrepostos e assertividade (BOCHKOVSKIY; WANG; LIAO, 2020). Esses fatores são fundamentais para o reconhecimento de plantas daninhas em tempo real, uma vez que podem possibilitar o rápido processamento e reconhecimento para a aplicação do herbicida no alvo em tempo hábil, sem a necessidade de coleta prévia para a montagem dos mapas de aplicação (SIVAKUMAR et al., 2020). No entanto, a velocidade de processamento ainda é um dos principais gargalos para possibilitar o reconhecimento e a aplicação localizada de herbicidas.

A arquitetura YOLO foi proposta por Redmon et al (2016) e evoluiu para diferentes versões. A versão 3 (YOLOv3) alcançou precisão e velocidade e se tornou a rede mais utilizada para detecção de objetos (BOCHKOVSKIY; WANG; LIAO, 2020). A partir das modificações feitas para melhorar a precisão e velocidade, a YOLO evoluiu para as versões YOLOv4 (BOCHKOVSKIY; WANG; LIAO, 2020), Scaled-YOLOv4 (WANG; BOCHKOVSKIY; LIAO, 2020), YOLOv5 (JOCHER et al., 2020), YOLOv6 (LI et al., 2022), YOLOv7 (WANG; BOCHKOVSKIY; LIAO, 2022) e YOLOv8 (https://ultralytics.com/) lançado em janeiro de 2023. A YOLOv8 é a interação recente dos modelos YOLO, que apresenta maior desempenho em termos de precisão e velocidade. No entanto, a procura pela otimização dos parâmetros do algoritmo com base no uso e conjunto de dados específicos é relevante para encontrar os melhores resultados. Recentemente, alguns estudos foram conduzidos com a YOLOv8 para detecção de plantas daninhas em gramados (GUO et al., 2023; SPORTELLI et al., 2023), repolho (SUN et al., 2024) e milho (HASAN et al., 2024; ZHU et al., 2024). Assim, nenhum desses trabalhos avaliou a YOLOv8 para o reconhecimento de plantas daninhas na cultura de soja. Dessa forma, o objetivo do estudo foi avaliar o desempenho da YOLOv8 e suas variantes com e sem pré-treino e reduzir o tamanho dos parâmetros das redes para melhorar a velocidade de processamento para possibilitar o reconhecimento de classes de plantas daninhas na cultura da soja.

OBJETIVOS

O objetivo do estudo foi avaliar o desempenho da YOLOv8 e suas variantes com e sem pré-treino e reduzir o tamanho dos parâmetros das redes para melhorar a velocidade de processamento para possibilitar o reconhecimento de classes de plantas daninhas na cultura da soja.

MATERIAL E MÉTODOS

As imagens para a composição do *dataset* foram obtidas em áreas de soja nos municípios de Fazenda Vilanova e Eldorado do Sul, no estado do Rio Grande do Sul, Brasil. Para a captura das imagens foi utilizado câmera Sony (SONY Corporation, Minato, Tokyo, Japan) a ~1,0 metros de altura do solo entre o período de novembro a março de 2020-2022 e 2022-2023. As fotos foram obtidas em diferentes condições de luz solar, incluindo dias claros, parcialmente nublados e nublados. O *dataset* final foi composto por espécies de plantas daninhas em convivência com a cultura da soja, com estádios de crescimento variável. Para as plantas daninhas as fotos obtidas apresentaram plântulas a

plantas daninhas adultas com inflorescência, já para a soja, as fotos apresentaram plantas em estádio VC (cotiledonar) a R3 (início da formação do legume) de desenvolvimento. As plantas daninhas presentes nas imagens foram classificadas como dicotiledôneas (folha larga) e monocotiledôneas (folha estreita), sendo que, para folha larga, foram priorizadas as espécies: caruru (*Amaranthus* spp.), buva (*Conyza* spp.), corriola (*Ipomoea* spp.), poaia branca (*Richardia brasiliensis*), picão-preto (*Bidens pilosa*), guanxuma (*Sida rhombifolia*) e leiteiro (*Euphorbia heterophylla*). Para folha estreita, foram priorizadas as espécies de papuã (*Brachiaria plantaginea*), capim-pé-de-galinha (*E. indica*), capim-carrapicho (*Cenchrus echinatus*) e capim-colchão (*Digitaria horizontalis*).

A arquitetura da YOLO é um método de aprendizado supervisionado. Por isso, houve a necessidade de anotação manual dos objetos. As anotações foram realizadas com auxílio de um software livre de interface gráfica denominado LabelImag (SourceForge.net). Nessa interface gráfica, foram criadas caixas delimitadoras (*bounding boxes*) no entorno de cada planta presente nas imagens. As imagens anotadas apresentaram um total de 21.092; 47.075 e 26.242 instâncias para a soja, plantas daninhas dicotiledôneas e plantas daninhas monocotiledôneas, respectivamente (Tabela 1). O *dataset* foi dividido em 80% das imagens para treinamento, 10% para teste e 10% para validação das redes neurais, o que representou um total de 1.563; 196 e 195 imagens, respectivamente.

Tabela 1. Número total de instâncias anotadas para cada classe nas fases de treinamento, teste e validação.

Classes	Treinamento (1.563 imagens)	Teste (196 imagens)	Validação (195 imagens)
	Instâncias		
Soja	17.415	1.839	1.838
Dicotiledôneas	37.736	3.941	5.398
Monocotiledôneas	20.923	2.429	2.890

Nove versões da YOLOv8 foram utilizadas para o treinamento. Cabe salientar que desse total, cinco são versões originais propostas pela YOLOv8 (YOLOv8 Rede 1, YOLOv8 Rede 2, YOLOv8 Rede 3 e YOLOv8 Rede 4) e as outras quatro foi realizada a otimização do número de parâmetros (YOLOv8 Rede 5, YOLOv8 Rede 6, YOLOv7 Rede 8 e YOLOv8 Rede 9). As cinco versões originais foram utilizadas inicialmente para verificar o desempenho com o pré-treino dos pesos versus sem pré-treino. A técnica de pré-treino da rede neural já foi utilizada conforme estudo conduzido com a YOLOv5x (ZHANG et al., 2022). O modelo gerado com as cinco versões originais da YOLOv8 (sem pré-treino) foi utilizado também para comparar o desempenho com as outras quatro redes obtidas com a otimização do número de parâmetros.

Neste trabalho foi realizada a validação cruzada (*cross validation*) em arquiteturas com melhor desempenho para reforçar a confiabilidade dos resultados (RASCHKA, 2020). Assim, foi aplicado a validação cruzada quíntupla para avaliar o desempenho dos modelos onde o conjunto de dados foi dividido em cinco subconjuntos usando imagens aleatórias. Os dois modelos foram treinados e testados cinco vezes (k=5), para cada rodada utilizou-se um subconjunto diferente como conjunto de validação.

As métricas avaliativas utilizadas foram o mAP (*Mean Average Precision*) e GFLOPs (*Giga Floating Point Operations Per Second*). O mAP é valor da média calculado a partir do valor da média das previsões de todas as classes. Foi utilizado o limite de interseção da união IoU (*Intersection Over Union*) entre as plantas anotadas e as caixas delimitadoras previstas de 0,5 (50%) (HENDERSON; FERRARI, 2017). O IoU é usado para medir a sobreposição entre as caixas delimitadoras oriundas da anotação manual e a caixa delimitadora prevista pela YOLOv8. O GFLOPs é expresso em bilhões

(10^9) de operações de ponto flutuante por segundo e indica o desempenho das unidades de processamento, ou seja, o desempenho computacional.

RESULTADOS E DISCUSSÃO

A partir dos resultados obtidos com o treinamento dos modelos originais da rede neural YOLOv8 (YOLOv8 Rede 1, YOLOv8 Rede 2, YOLOv8 Rede 3, YOLOv8 Rede 4, YOLOv8 Rede 5) foi verificado um platô no desempenho tanto para arquiteturas sem pré-treino quanto para aquelas com pré-treino (Tabela 2). As redes sem pré-treino apresentaram desempenhos similares às redes pré-treinadas, ambas com valores de mAP50 entre 0,70 e 0,73. Interessantemente, a arquitetura YOLOv8 Rede 1 apresentou valores de mAP50 de 0,70 e 0,71; com número significativamente menor de parâmetros 3.157.200 e 3.006.233; para treinamentos sem e com pré-treino, respectivamente. Por outro lado, as arquiteturas YOLOv8 Rede 4 e YOLOv8 Rede 5 aumentaram o mAP50 de 0,71 para 0,73 quando pré-treinadas. No entanto, ambas as arquiteturas apresentam um número significativo de parâmetros 43.691.520 e 68.229.648 e GFLOPs 165,7 e 258,5, respectivamente. O interesse por arquiteturas com menor número de parâmetros sem reduzir a performance da rede, conforme foi verificado para YOLOv8 Rede 1, aumenta em sistemas embarcados para garantir a velocidade de processamento dos dados. Cabe salientar que o benefício do uso da técnica com pré-treino foi verificado em estudo conduzido com a YOLOv5 (JUNIOR; ALFREDO C. ULSON, 2021). Nesse estudo foram avaliadas YOLOv5s, YOLOv5m, YOLOv5l e YOLOv5x; as quatro arquiteturas apresentaram melhorias significativas com pré-treino. Sendo a YOLOv5s com aumento do acurácia de 0,45 para 0,71. Outro trabalho avaliou três tipos de CNNs, as quais foram pré-treinadas com ImageNet para inicializar os pesos e bias através da abordagem do transfer learning (JIN et al 2022). No entanto, esse trabalho não avaliou o desempenho da rede neural sem pré-treino, somente comparou as três redes neurais utilizadas. Apesar dessas análises em outros trabalhos, o desempenho similar entre o pré-treino e sem pré-treino do presente estudo, sugere que a prévia iniciação dos pesos pode não ser crucial para determinadas configurações.

Tabela 2. Comparação dos modelos originais da rede neural YOLOv8 gerados sem e com pré-treino.

Modelo	Parâmetros	GFLOPs	mAP50
Sem pré-treino			
YOLOv8-Rede 1	3.157.200	8,90	0,70
YOLOv8-Rede 2	11.166.560	28,80	0,71
YOLOv8-Rede 3	25.902.640	79,30	0,71
YOLOv8-Rede 4	43.691.520	165,70	0,71
YOLOv8-Rede 5	68.229.648	258,50	0,71
Com pré-treino			
YOLOv8-Rede1	3.006.233	8,10	0,71
YOLOv8-Rede 2	11.126.745	28,40	0,71
YOLOv8-Rede 3	25.841.497	78,70	0,71
YOLOv8-Rede 4	43.608.921	164,80	0,73
YOLOv8-Rede 5	68.126.457	257,40	0,73

A partir dos resultados verificados na tabela 2 houve o interesse em investigar a partir de qual arquitetura a eficácia começa a estagnar. Ao analisar as quatro redes YOLOv8 Rede 6, YOLOv8 Rede 7, YOLOv8 Rede 8, YOLOv8 Rede 9 com número menor de parâmetros <1.000.000, verificou-se menores valores de GFLOPs: 5,2; 2,6; 7,1; e 1,4; e maiores de mAP50: 0,70; 0,67; 0,70; e 0,58; respectivamente (Tabela 3). Já as versões originais YOLOv8 Rede 1, YOLOv8 Rede 2, YOLOv8 Rede 3, YOLOv8 Rede 4, YOLOv8 Rede 5 propostas pelos desenvolvedores da YOLOv8 com

número de parâmetros >3.000.000 apresentaram valores maiores de GFLOPs: 8,9; 28,8; 79,3; 165,7; 258,5; respectivamente, e mantiveram o mAP50 entre 0,70 e 0,71. Esses resultados indicam que as quatro redes com menos parâmetros do que as versões originais propostas pelos desenvolvedores da YOLOv8 apresentaram perda mínima de performance. Isso é evidenciado, principalmente, com a arquitetura YOLOv8 Rede 6 com número significantemente menor de parâmetros (904.633). Entre as versões originais, a YOLOv8 Rede 1 apresentou performance similar às demais com número de parâmetros significativamente menor (3.000.000). Estudo realizado com as cinco versões originais da YOLOv8 (YOLOv8 Rede 1, YOLOv8 Rede 2, YOLOv8 Rede 3, YOLOv8 Rede 4 e YOLOv8 Rede 5) verificou diferenças significativas entre essas arquiteturas, sendo que a YOLOv8 Rede 3 destacou-se com mAP de 0,87 (HASAN et al., 2024). O número de parâmetros está diretamente relacionado a mensuração da complexidade do modelo, além de exigir uma quantidade maior de memória para implantação e afeta o custo e tempo de inferência (DANG et al., 2023). A partir dos resultados verificados na tabela 3, optou-se por realizar cross validation para as arquiteturas YOLOv8 Rede 1 e YOLOv8 Rede 6 para reforçar a confiabilidade dos resultados encontrados.

Tabela 3. Desempenho das cinco arquiteturas originais da YOLOv8 sem pré-treino (do zero) versus as quatro redes com otimização dos parâmetros.

Modelo	Layers	Parâmetros	GFLOPs	mAP50
YOLOv8 Rede 1 (do zero)	225	3.157.200	8,9	0,70
YOLOv8 Rede 2 (do zero)	225	11.166.560	28,8	0,71
YOLOv8 Rede 3 (do zero)	295	25.902.640	79,3	0,71
YOLOv8 Rede 4 (do zero)	365	43.691.520	165,7	0,71
YOLOv8 Rede 5 (do zero)	365	68.229.648	258,5	0,71
YOLOv8 Rede 6	225	904.633	5,2	0,70
YOLOv8 Rede 7	225	361.001	2,6	0,67
YOLOv8 Rede 8	225	1.866.457	7,1	0,70
YOLOv8 Rede 9	225	198.561	1,4	0,58

A confiabilidade dos resultados obtidos em relação ao desempenho das arquiteturas YOLOv8 rede 1 e YOLOv8 Rede 6 foi confirmada com a realização do cross validation (Tabela 4). Os valores de mAP50 foram de 0,70 a 0,73 para ambas as arquitetura, esses valores são próximos aos que foram verificados anteriormente (Tabela 3). A YOLOv8 Rede 6 manteve o GFLOPs em 5,2 em cada interação. Para essa rede os valores de mAP50 ficaram entre 0,70 a 0,72 para as cinco interações realizadas. Da mesma forma, para YOLOv8 Rede 1 o GFLOPs manteve-se constante nas cinco interações com mAP50 variando de 0,69 a 0,73.

Tabela 4. Parâmetros após a realização do Cross validation para as arquiteturas YOLOv8 Rede 1 e YOLOv8 Rede 6.

Modelo	Interações	Parâmetros	GFLOPs	mAP50
YOLOv8 Rede 1	1	3.006.233	8,1	0,70
	2	3.006.233	8,1	0,69
	3	3.006.233	8,1	0,71
	4	3.006.233	8,1	0,71
	5	3.006.233	8,1	0,73
YOLOv8 Rede 6	1	904.633	5,2	0,70
	2	904.633	5,2	0,70
	3	904.633	5,2	0,70
	4	904.633	5,2	0,71
	5	904.633	5,2	0,72

CONCLUSÃO

Este é o primeiro estudo comparado diferentes variantes da última versão da YOLO lançada em 2023 (YOLOv8) e com otimização de parâmetros para detecção de plantas daninhas verificadas no Brasil para a cultura da soja. As variantes da YOLOv8 sem pré-treino apresentam desempenho similar às redes pré-treinadas. A redução do número de parâmetros pode ser uma importante ferramenta para reduzir a complexidade e processamento de dados sem afetar o desempenho das arquiteturas.

AGRADECIMENTOS

Aos alunos de iniciação científica do Grupo Universitário de Investigações em Herbologia da UFRGS (GUIHE-UFRGS) pelo auxílio nas coletas e anotações de imagens. Ao CNPq pelo financiamento da bolsa de doutorado da aluna responsável pelo desenvolvimento do presente trabalho.

REFERÊNCIAS

BOCHKOVSKIY, A; WANG, CY; LIAO, HYM. YOLOv4: Optimal Speed and Accuracy of Object Detection. **Arxiv**, v.2004, p.10934, 2020.

DANG, F. et al. YOLOWeeds: A novel benchmark of YOLO object detectors for multi-class weed detection in cotton production systems. **Computers and Electronics in Agriculture**, v. 205, p. 107655, 2023.

GERHARDS, R; SANCHEZ, DA; HAMOUZ, P; PETEINATOS, GG; CHRISTENSEN, S; QUINTANILLA, CF; Advances in site-specific weed management in agriculture - A review. **Weed Research**, v.62, p.123-133, 2022.

HASAN, A. S. M. M. et al. Object-level benchmark for deep learning-based detection and classification of weed species. **Crop Protection**, v. 177, p. 106561, 2024.

HENDERSON, P.; FERRARI, V. **End-to-end training of object class detectors for mean average precision**. arXiv, 16 mar. 2017. Disponível em: <http://arxiv.org/abs/1607.03476>. Acesso em: 30 mar. 2024

JIN X., et al. A novel deep learning-based method for detection of weeds in vegetables. **Pest Management Science**, v. 78 n. 5 p. 1861-1869, 2022.

JOCHER, G., 2020. yolov5. Code repository. https://github.com/ultralytics/yolov5. Stanford (2022) Tutorial 3: Image Segmentation. ~https://ai.stanford.edu/ ~syyeung/cvweb/tutorial3.html. Acesso: July, 2022

JUNIOR, L. C. M.; ALFREDO C. ULSON, J. Real Time Weed Detection using Computer Vision and Deep Learning. 2021 14th **IEEE International Conference on Industry Applications (INDUSCON).** Disponível em: <https://ieeexplore.ieee.org/document/9529761/>. Acesso em: 1 abr. 2024

KAMILARIS, A; PRENAFETA-BOLDÚ, FX. Deep Learning in Agriculture: A Survey. **Computers and Eletronics in Agriculture**, v.147, p.70-90, 2018.

LI, C. et al. YOLOv6: A Single-Stage Object Detection Framework for Industrial Applications. 7 set. 2022.

LECUN, Y; BENGIO, Y; HINTON, G. Deep learning. **Nature**, v.521, p.436-444, 2015.

RASCHKA, S. Model Evaluation, Model Selection, and Algorithm Selection in Machine Learning. **arXiv**, 10 nov. 2020. Disponível em: <http://arxiv.org/abs/1811.12808>. Acesso em: 7 abr. 2024

REDMON, J. et al. You only look once: Unified, real-time object detection. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Anais**. IEEE Computer Society**, 9 dez. 2016.

SCHMIDHUBER, J. Deep Learning in neural networks: An overview. **Neural Networks**, v.61, p.85-117, 2015.

SIMONYAN, K; ZISSERMAN, A. Very Deep Convolutional Networks for Large-Scale Image Recognition. **CoRR**, v. abs/1409.1556, 2014.

SIVAKUMAR, A. N. V. et al. Comparison of object detection and patch-based classification deep learning models on mid-to late-season weed detection in UAV imagery. **Remote Sensing**, v. 12, n. 13, 2020.

STEEN, K. A. et al. Using deep learning to challenge safety standard for highly autonomous machines in agriculture. **Journal of Imaging**, v. 2, n. 1, 2016.

SUN, H. et al. Evaluation of two deep learning-based approaches for detecting weeds growing in cabbage. **Pest Management Sci**, 2024.

WANG, C.-Y.; BOCHKOVSKIY, A.; LIAO, H.-Y. M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. 2022.

ZHANG, J.-L. et al. SE-YOLOv5x: An Optimized Model Based on Transfer Learning and Visual Attention Mechanism for Identifying and Localizing Weeds and Vegetables. **Agronomy**, v. 12, n. 9, p. 2061, 29 ago. 2022.

3. Economia

OBTENÇÃO DE ANÁLISES SOCIOECONÔMICAS COM A INTRODUÇÃO DE SÉRIES TEMPORAIS DE ORTOIMAGENS: UMA PROPOSIÇÃO COM BASE NA AGRICULTURA DE PRECISÃO.

Helena Fantin Gebler [1]

[1]Estudante. Av. Luiz de Camões, 2090 - Conta Dinheiro, Lages - SC, 88520-000. Universidade Estadual de Santa Catarina

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

É sabida a importância da utilização de ortoimagens em séries temporais para o estudo do impacto da variabilidade temporal no manejo de culturas, sendo pouco explorado o potencial dessa metodologia para estudos socioeconômicos, principalmente sua aplicabilidade para geração de mapas de rentabilidade das áreas ao longo do tempo. Dessa forma, este resumo busca explanar as razões da necessidade de destaque de ferramentas da agricultura de precisão em estudos econômicos, utilizando estudos de solo de Santa Catarina como pano de fundo.

PALAVRAS-CHAVE: Análise do solo; Economia brasileira; Socioeconomia

ABSTRACT

The importance of Ortho imagery in the production of time series for the study of temporal variability in agronomic cultures is known, but its potential for socioeconomic studies has been little explored, especially its applicability for generating area rentability maps over time. This work uncovers the reasons for the tools of precision agriculture to be applied in socioeconomic studies, with Santa Catarina's soil use studies as background.

KEYWORDS: Soil analysis; Brazilian economy; Socioeconomics

INTRODUÇÃO

Na agricultura de precisão, ferramentas de avaliação da variabilidade espacial são bastante usuais, sendo seu principal exemplo os mapas de fertilidade de solos. Entretanto, a variabilidade temporal também tem espaço de destaque na análise quando se dispõe de séries temporária viáveis, que permitam acompanhar as variações das informações geradas ao longo do tempo (MAGRO et al., 2023). Uma dessas possíveis ferramentas de análise seriam os mapas de rentabilidade das áreas, pois permitem estabelecer pontos de significância em comum ao longo do tempo (renda gerada por ponto).

Estudos socioeconômicos são ferramentas importantes para a obtenção de dados sobre o comportamento de grupos sociais e a forma como isso influencia o mercado. Para Davis e Dolfsma (2008), ao observar a economia levando em conta somente a forma como a humanidade lida com seus recursos escassos, variáveis como desigualdade social, sustentabilidade ou dignidade humana são ignorados e o observador falha e captar a natureza mais profunda da atividade econômica, que é intrinsecamente social. Dessa forma, a importância que a interdisciplinaridade de estudos socioeconômicos, como o executado em: "Relação entre solos e a economia os planaltos de Santa Catarina", é relevante nesse campo, assim como a previsibilidade dos resultados dessa pesquisa. Assim, a atividade econômica realizada nos planaltos catarinenses varia de acordo com o solo predominante de cada área, permitindo uma análise da variabilidade temporal da renda sobre uma área física, e em consequência, a análise de rentabilidade ao longo do tempo com base nestes mapas.

Portanto, é indutivo concluir que a consequência de diferentes profundidades, pHs e concentrações minerais de um solo interfiram na atividade econômica realizada nele.

O objetivo deste trabalho foi demonstrar a viabilidade do uso de ferramentas de agricultura de precisão com ênfase na análise de séries temporais para a obtenção de informações socioeconômicas das áreas de estudo.

OBJETIVOS

O objetivo desse resumo foi avaliar séries temporais de ortoimagens obtidas por meio de análise de variabilidade e verificar seu potencial como referência em estudos socioeconômicos.

MATERIAL E MÉTODOS

Foi feita uma análise bibliográfica com base em trabalhos provenientes tanto de Centros de pesquisa nacionais - como Embrapa e EPAGRI - quanto de grupos de pesquisa individuais, de diversos centros universitários. O fio condutor deste trabalho foi com base no *paper* publicado pelo Programa Universitário Tcheco-brasileiro em 2023, *Connection between soil and economy of plateaus of Santa Catarina,* de modo a estudar formas de melhorar sua análise socioeconômica utilizando meios digitais de obtenção de dados, com ênfase no estudo de séries temporais de ortoimagens, tecendo considerações da extensão desta análise como ferramenta da agricultura de precisão, principalmente levando em conta a variabilidade temporal.

RESULTADOS E DISCUSSÃO

Considerando o intrínseco valor multidisciplinar do estudo socioeconômico, tal qual defendem Davis e Dosfsma (2008), é proveitosa ao âmbito científico a utilização de diversas ferramentas para permitir resultados mais acurados deste, mesmo que essas não tenham se originado, necessariamente, para essa função. Para Arlindo e Silva Neto (2011), a interdisciplinaridade, é (...) um processo que exige mudanças na modalidade de produção de conhecimento, implicando transformações individuais e institucionais. Tendo isso em mente e utilizando como base de estudo o artigo "Conexão entre tipos de solo e economia de Santa Catarina" (ONEDA, STEFFENS, GEBLER. 2023), é possível indagar que outras ferramentas muito utilizadas no campo da pesquisa de solos poderiam ser utilizadas numa lente socioeonômica; entre elas, a utilização de ortoimagens chama a atenção, principalmente somada à produção de séries temporais.

Para Morettin e Toloi (2004), ao se realizar um estudo de séries temporais, pode-se estar interessado em: a) investigar o mecanismo gerador da série temporal; b) fazer previsões de valores futuros da série; c) descrever apenas o comportamento da série, como tendências e sazonalidades, por exemplo; d) procurar periodicidades relevantes nos dados. Atualmente, é tão comum que os estudos com ortoimagens que utilizam essa ferramenta tenham enfoque nos dois últimos objetivos quanto incomum que elas sequer considerem o primeiro: trabalhos como os de Ren et al. (2020) demonstram como a produção de séries temporais com ortoimagens pode ajudar a entender a fenologia de espécies, sua produtividade ou sua resposta a situações de estresse, provando a utilidade dessa metodologia para questões de manejo. É interessante, porém, considerar como essa metodologia pode ser utilizada, por exemplo, como apoio para estudar não só o uso da terra, mas também o comportamento das pessoas que utilizam aquela terra, e a razão delas escolherem utilizá-la daquela forma.

Utilizar séries temporais de ortoimagens em um estudo como "Conexão entre tipos de solo e economia de Santa Catarina", o qual possui uma visão socioeconômica, além de permitir a visualização do uso do solo de Santa Catarina com o passar dos anos, permitiria relacionar o manejo não só com questões edafoclimáticas, mas também com questões sociais: no artigo de 2023, foi concluído que regiões de

solo melhor estruturado dão preferência a cultivos anuais, em contraste com as culturas perenes preferidas em regiões de solo mais pobre; por meio de séries temporais de ortoimagens, seria possível compreender melhor padrões como crescimento urbano em anos de colheita de Pinus ou arrendamentos de terra e culturas mais plantadas em dada região.

CONCLUSÃO

Séries temporais de ortoimagens obtidas por meio de análise de variabilidade na agricultura de precisão apresentam potencial como referência em estudos socioeconômicos, não só por fornecerem mapas detalhados de uso da terra (uso econômico) mas também porque registram a evolução de uma comunidade e suas relações socioeconômicas, através do estudo da variabidade temporal.

REFERÊNCIAS

MAGRO, R. B. ; ALVES, S. A. M. ; GEBLER, L. ; GEBLER, L. . **Computational Models in Precision Fruit Growing: Reviewing the Impact of Temporal Variability on Perennial Crop Yield Assessment.** SN Computer Science, v. 4, p. 554, 2023.

DAVIS, J. B; DOLFSMA, W. **Social Economics: An Introduction and a View of the Field.** The Elgar Companion to Social Economics, Cheltenham, UK, 2008, p.1-7. Disponível em: https://core.ac.uk/download/pdf/213081318.pdf

PIERCE, F. J.; NOWAK, P**. Aspects of precision agriculture. Advances in Agronomy**, San Diego, v. 67, p. 1-85, 1999.

JR., Arlindo, P.; SILVA, A. J. N. **Interdisciplinaridade em Ciência, Tecnologia & Inovação.** Editora Manole, 2011, p.17.

ONEDA, E. B. STEFFENS G. L. GEBLER, H. F. **Connection between soil and economy of plateaus of Santa Catarina.** UNIGOU Training 2023. 2023. Disponível em: https://incbac.org/pdf/UNIGOU%20Training%20-%20Publication%202023%20-%20Helena%20Fantin%20Gebler.pdf

MORETTIN, P. A.; TOLOI, C. M. C. A**nálise de Séries Temporais**. São Paulo: Edgar Blucher Ltda., 2004.

REN, T.; LIU, Z.; ZHANG, L.; LIU, D.; XI, X.; KANG, Y.; ZHAO, Y.; ZHANG, C.; LI, S.; ZHANG, X. **Early Identification of Seed Maize and Common Maize Production Fields Using Sentinel-2 Images**. Remote Sens. 2020, 12, 2140. https://doi.org/10.3390/rs12132140

DETERMINANTES DA ADOÇÃO DE TECNOLOGIAS DE PRECISÃO NA BOVINOCULTURA: UMA REVISÃO SISTEMÁTICA DA LITERATURA

Leticia Caroline da Silva David [1]; Marcelo José Carrer [2]; Marcela de Mello Brandão Vinholis [3]; Andrea Lago da Silva [2]; Hildo Meirelles de Souza Filho [2]

[1]Mestranda. Rod. Washington Luís, km 235 - SP-310, São Carlos, 13565-905. Universidade Federal de São Carlos; [2]Docente. Rod. Washington Luís, km 235 - SP-310, São Carlos, 13565-905. Universidade Federal de São Carlos; [3]Pesquisadora. Rod. Washington Luís, km 234 - Fazenda Canchim - SP, São Carlos, 13560-970. Embrapa Pecuária Sudeste

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Este artigo tem como objetivo identificar as principais tecnologias digitais adotadas por bovinocultores no mundo e os fatores que influenciam a adoção. O método adotado foi a revisão sistemática de literatura. Os resultados sugerem que o conjunto de tecnologias adotadas está associado ao sistema de produção. Sistemas de produção de gado de corte estão associados às tecnologias de Aquisição de dados e comunicação tecnológica e de Sistemas de Informação, enquanto que sistemas de produção de gado de leite às tecnologias de Automação, Controle e Robótica e de Aquisição de dados e comunicação tecnológica. Dentre os fatores que influenciam a adoção tem-se as características socioeconômicas do produtor, como idade, grau de escolaridade e gênero, características da produção e da propriedade rural, como escala de produção, condições e tipo de instalações. Ainda foram destacadas barreiras à adoção associadas ao elevado investimento inicial, a relação custo-benefício, a desconfiança quanto à privacidade dos dados e a falta de conhecimento associado à complexidade de uso de algumas tecnologias. Os resultados do estudo podem contribuir para o desenvolvimento de novas políticas públicas e auxiliar os bovinicultores na tomada de decisões. Além disso, foi observada uma escassez de estudos sobre os determinantes da adoção de tecnologias digitais na bovinocultura, especialmente na pecuária de corte, evidenciando uma lacuna na pesquisa.

PALAVRAS-CHAVE: gado bovino; RSL;

ABSTRACT

This article aims to identify which digital technologies are being adopted by cattle farmers around the world and also verify which are the main factors that influence this adoption. To achieve these objectives, a systematic literature review was carried out. From the review it can be obtained as a result that there are different adoption of technology depending on the production system, with beef cattle producers tending to adopt Data Acquisition and Technological Communication and Information Systems technologies and dairy cattle producers adopt more Automation, Control and Robotics and Data Acquisition technologies with a focus on livestock monitoring. Furthermore, it can be seen that the factors that most influence adoption are characteristics of production and rural property and socioeconomic characteristics and conditions of the producer. The study's results can contribute to the development of new public policies and assist cattle breeders in decision-making. Additionally, a scarcity of studies on the determinants of digital technology adoption in cattle farming, particularly in beef production, has been observed, highlighting a research gap.

KEYWORDS: ;

INTRODUÇÃO

O setor pecuário tem grande importância para o Brasil, tanto como fonte de alimento, renda e emprego para o mercado interno, como na exportação de alimento para o mundo e geração de divisas para o país. O Brasil é o terceiro maior produtor mundial de leite e o maior produtor comercial de carne bovina (ABIEC, 2023; IBGE, 2021). Esta grandeza da pecuária nacional traz consigo o desafio da produção mais sustentável e com menor impacto ambiental. A adoção de tecnologias de precisão e digital pode contribuir para ganhos de eficiência e agregação de valor, em direção à produção mais sustentável.

A pecuária de precisão refere-se à aplicação estratégica e integrada de tecnologias avançadas, como sensores, automação, análise de dados e sistemas de informação, para otimizar a gestão e o desempenho de operações pecuárias. Essa abordagem visa melhorar a eficiência, a produtividade e o bem-estar dos animais, promovendo uma gestão mais precisa e informada das atividades pecuárias (MORRONE et al., 2022).

A decisão de adoção de tecnologias agropecuárias pode ser influenciada tanto positiva quanto negativamente por um conjunto de fatores, que incluem características socioeconômicas e condições do produtor, características da produção e da propriedade rural, características da tecnologia, e fatores ambientais ou sistêmicos (GEROSKI, 2000; SOUZA FILHO et al., 2011). Estudos empíricos e de revisão de literatura têm demonstrado alguns fatores que impactam a decisão de adoção de tecnologias digitais na agricultura (BARNES et al., 2019; CARRER et al., 2017; GIUA et al., 2021; MOZAMBANI et al., 2023; TEY e BRINDAL, 2012; 2022; VINHOLIS et al., 2017). Não se verificou na literatura estudo de revisão dedicado a investigar a adoção as tecnologias digitais na pecuária bovina.

O conhecimento sobre o estado da arte em adoção das tecnologias digitais na pecuária bovina e os fatores que a influenciam contribuem para o desenho de ações do setor e políticas específicas para o fomento da adoção dessas tecnologias. Este estudo tem por objetivo identificar as principais tecnologias digitais adotadas por bovinocultores no mundo e os fatores que influenciam a adoção. Seguindo a classificação de categorias proposta por Moreno (2024), esta pesquisa focará na adoção das tecnologias classificadas nas categorias: Automação, Controle e Robótica; Computação e tecnologia em nuvem; Aquisição de dados e comunicação; Ciência de dados e Inteligência artificial; Sistemas de Informação.

OBJETIVOS

O objetivo do presente estudo é, por meio de Revisão Sistemática de Literatura, responder às seguintes questões: "Quais são as tecnologias digitais adotadas por produtores na bovinocultura?" e "Quais são os determinantes de adoção de tecnologias digitais na bovinocultura?".

MATERIAL E MÉTODOS

A metodologia escolhida para o presente estudo foi a Revisão Sistemática de Literatura, que através de uma abordagem rigorosa busca identificar, analisar e sintetizar de maneira imparcial e abrangente todas as evidências disponíveis relacionadas a uma pergunta específica de pesquisa. A realização da revisão sistemática foi feita utilizando o protocolo Prisma (MOHER et al., 2010).

A partir de conhecimentos obtidos através da revisão de escopo puderam ser levantadas duas questões de pesquisa que nortearam esse trabalho. São elas:

- Q1: Quais são as tecnologias digitais adotadas por produtores na bovinocultura?
- Q2: Quais são os determinantes de adoção de tecnologias digitais na bovinocultura?

As bases utilizadas como fonte de dados para a pesquisa foram a Scopus e a Web of Science (WoS), sendo estas escolhidas por serem as mais conceituadas no mundo. A busca realizada consistiu em pesquisar no título, resumo e palavras chaves dos artigos, os termos contidos na string referente a cada um dos construtos dispostos na tabela 1. Além disso, também foram aplicados os seguintes filtros para a seleção dos artigos a serem analisados no estudo, artigos escritos na língua inglesa e que tivessem passado pelo procedimento de revisão por pares, por consequência sendo excluídos capítulos de livros, artigos resultantes de conferências e demais "objetos" que não se enquadram em revisado por pares. Ademais, a busca foi realizada sem a restrição de uma data inicial de publicação, porém com data limite de publicação dos artigos até o dia 31/12/2023. Não foram aplicados filtros quanto aos indicadores das revistas as quais os artigos são provenientes e nem em relação ao acesso ao artigo.

TABELA 1 - Protocolo da revisão sistemática

Questão	Construtos	String
Quais as tecnologias digitais adotadas por bovinocultores?	Tecnologia digital	((Digit* OR Precision OR Smart OR Intelligent OR Automat* OR "4.0") w/0 (Agri* OR Livestock OR Farm* OR Rural))
Quais são os determinantes de adoção de tecnologias digitais na bovinocultura?	Adoção	(Adopt* OR Diffus* OR Transf* OR Dissemin*)
	Bovinocultura	(Beef OR Dairy OR Cattle OR Livestock OR Ruminant* OR (Animal W/0 Husbandry) OR Breed*)

Fonte: Autoria própria

A busca inicial retornou 654 documentos na base Scopus e 470 na WoS. Após a exclusão dos documentos não revisados por pares foram mantidos 372 documentos na Scopus e 322 na WoS. Após a remoção dos documentos que não eram em língua inglesa foram mantidos 342 e 315, respectivamente. Em seguida foram excluídos 246 artigos duplicados nas bases, restando 411 artigos candidatos à análise de conteúdo.

A partir da leitura de títulos e resumos, 361 estudos foram excluídos por falta de aderência ao tema (adoção de tecnologia digital no sistema de produção de bovinocultura). Os 50 artigos restantes foram analisados considerando suas introduções, metodologias e conclusões para responder às questões deste estudo. Apenas 14 artigos atenderam o propósito da investigação.

Com o intuito de aumentar o tamanho amostral de artigos, a técnica de amostragem por snowball possibilitou a inclusão de outros cinco estudos na investigação. A leitura completa do conjunto de 19 estudos possibilitou identificar as principais tecnologias digitais adotadas na bovinocultura e os fatores que influenciam a adoção. A análise do conteúdo dos artigos e a discussão são apresentadas na próxima seção. O software estatístico R (R CORE TEAM, 2022) foi utilizado na realização das estatísticas descritivas e na geração dos gráficos.

RESULTADOS E DISCUSSÃO

O conjunto de 19 artigos foi reconhecido como fortemente relacionado ao tema abordado nesta revisão. Os 14 resultantes da busca nas bases Scopus ou WoS são: Abeni, Petrera, Galli (2019), Bianchi et al. (2022), Gabriel, Gandorfer (2023), Groher, Heitkamper, Umstatter (2020), Jelinski et al. (2020), Makinde, Islam, Wood (2022), Marescotti et al. (2021), Mendes et al. (2022), Newton, Nettle, Pryce (2020), Piña et al. (2023), Rajchamaha, Makararpong (2023), Rue et al. (2020), Silvi et al. (2021), Vrchota, Pech, Svepesova (2022). Os 5 artigos adicionados por meio da técnica snowball

foram: Boyer et al. (2024), Drewry, Shutske, Trechter (2019), Edwards, Dela Rue, Jago (2015), Gargiulo et al. (2018), Steeneveld, Hogeveen (2015). A Tabela 2 caracteriza os artigos.

Com a intenção de conduzir uma análise isenta de influências de adoção de tecnologias digitais em outras culturas, 79% dos estudos concentram-se exclusivamente no tema da bovinocultura, fornecendo informações específicas apenas sobre criadores de gado bovino. Os 21% restantes dos artigos que não se restringem aos dados exclusivos de produtores de bovinos apresentam uma discriminação dos valores dos respondentes em relação à bovinocultura. Assim, 26% dos estudos representam amostras com criadores de gado para produção de leite ou carne, 58% abrangem especificamente produtores de gado leiteiro, e apenas 16% são baseados em dados de criadores de gado de corte.

O artigo mais antigo utilizado para esta revisão foi publicado no ano de 2015. Os anos de 2020 e 2023 registraram uma frequência mais proeminente de artigos na amostra. Embora tenha-se observado uma diminuição na quantidade de artigos entre 2020 e 2021, há uma tendência crescente nas publicações associadas ao tema, notavelmente a partir de 2018. Não se constataram publicações correspondentes aos anos de 2016 e 2017.

Com relação a localização dos artigos, os países com maior quantidade de estudos realizados são Itália e Estados Unidos da América com três estudos em cada, sendo esses realizados nas regiões italianas de Cremona e Lombardy e nos estados americanos Oklahoma, New Mexico, Tennessee, Texas e Wisconsin. Brasil, juntamente com a Austrália, Canadá e Nova Zelândia, apresentam dois estudos conduzidos em cada nação. Foram observados apenas um estudo para cada um dos demais países.

TABELA 2 - Descrição dos estudos resultantes da revisão sistemática da literatura.

Ano	Autores	Exclusivo bovinos	Método de análise	Tamanho amostral	Região de estudo	Coleta dos dados
2019	ABENI, PETRERA, GALLI	Sim	Regressão logística	490 (Leite)	Itália (Cremona)	Questionário (Presencial)
2022	BIANCHI et al.	Sim	Modelo Linear Generalizado, Análise de componentes principais, Análise de correspondência múltipla	52 (Leite)	Itália (Lombardy)	Questionário (Eletrônico)
2024	BOYER et al.	Sim	Regressão logística	201(Corte)	EUA (Tennessee)	Questionário (Eletrônico)
2019	DREWRY, SHUTSKE, TRECHTER	Não	Regressão logística	1021 (Total) 387 (Leite) 405 (Corte)	EUA (Wisconsin)	Questionário (Carta)
2015	EDWARDS, DELA RUE, JAGO	Sim	Qui-quadrado, Anova, Análise de cluster	278 (Leite)	Nova Zelândia	Questionário (Telefone)
2023	GABRIEL, GANDORFER	Não	Bootstrap	2390 (Total) 888 (Leite) 199 (Corte)	Alemanha (Bayern)	Questionário (Eletrônico)
2018	GARGIULO et al.	Sim	Modelo Linear Generalizado	301 (Leite)	Austrália	Questionário (Eletrônico)
2020	GROHER, HEITKAMPER, UMSTATTER	Não	Regressão logística	1497 (Total) 247 (Leite) 195 (Corte)	Suiça	Questionário (Eletrônico)
2020	JELINSKI et al.	Sim	Regressão logística	26935 (Leite)	Canadá	Microdados StatsCan 2016
2022	MAKINDE, ISLAM, WOOD	Sim	Estatísticas descritivas	52 (Corte)	Canadá (Ontário)	Questionário (Eletrônico e presencial)
2021	MARESCOTTI et al.	Sim	Análise de cluster	63 (Leite)	Itália (Lombardy)	Questionário (Presencial)
2022	MENDES et al.	Sim	Regressão Poisson e Binária hurdle	175	Brasil (São Paulo)	Questionário (Presencial)
2020	NEWTON, NETTLE, PRYCE	Sim	Estudo de caso	7 (Leite)	Austrália	Estudo de caso
2023	PIÑA et al.	Sim	Regressão probit	84 (Corte)	EUA (New Mexico, Texas, Oklahoma)	Questionário (Eletrônico)
2023	RAJCHAMAHA, MAKARARPONG	Sim	Regressão linear múltipla	461 (Leite)	Tailândia (Nakhon Ratchasima, Saraburi)	Questionário (Presencial)
2020	RUE et al.	Sim	Estatísticas descritivas	500 (Leite)	Nova Zelândia	Questionário (Telefone)
2021	SILVI et al.	Sim	Análise de cluster	378 (Leite)	Brasil	Questionário (Eletrônico)
2015	STEENEVELD; HOGEVEEN	Sim	Análise discriminante linear	512 (Leite)	Holanda	Questionário (Eletrônico)
2022	VRCHOTA, PECH, SVEPESOVA	Não	Qui-quadrado	131	República Tcheca	Questionário (Eletrônico)

Fonte: Autoria própria

O método de estudo predominante nos documentos selecionados é de natureza quantitativa, sendo a metodologia de análise mais frequente para analisar os dados e atingir os objetivos dos estudos, a regressão logística ou probit. Essa técnica apareceu como metodologia em 42% dos estudos.

A maioria dos dados analisados nos estudos consiste em dados primários adquiridos por meio de questionários (survey) ou estudos de caso. Dados secundários foram utilizados em apenas um artigo (JELINSKI et al., 2020). Com exceção do artigo de Vrchota; Pech; Svepesova (2022), em que os respondentes eram gestores de empresa, os entrevistados dos outros estudos eram os próprios produtores, sendo incluídos na amostra veterinários e prestadores de serviço nos estudos de Makinde; Islam; Wood (2022) e Gargiulo et al. (2018), respectivamente.

A Tabela 3 mostra os periódicos em que os estudos foram publicados e o respectivo fator de impacto no ano de 2022, avaliado pelo índice Journal Citation Reports (JCR) e disponibilizado pela Clarivate. O periódico com maior quantidade de estudos foi o Computers and Electronics in Agriculture (15,8% dos estudos).

TABELA 3 - Periódicos em que os estudos foram publicados.

Periódico	Publicações	JCR
Computers and Electronics in Agriculture	3	8.3
Animal	2	3.6
Animal Production Science	2	1.4
Animals	2	3.0
Journal of Dairy Science	2	3.5
Agricultural Systems	1	6.6
Agriculture	1	3.6
Canadian Veterinary Journal	1	1.0
International Journal of Interactive Mobile Technologies	1	-
Journal of Agribusiness in Developing and Emerging Economies	1	2.4
Journal of Rural Studies	1	5.1
Precision Agriculture	1	6.2
Smart Agricultural Technology	1	-
Total	19	

Fonte: Autoria própria

A publicação com maior número de citações (119 vezes) é intitulada "Dairy farmers with larger herd sizes adopt more precision dairy technologies" (GARGIULO et al., 2018) (Tabela 4). Vale ressaltar que são recentes as publicações no tema do estudo. As primeiras publicações datam de 2015 e os anos de 2020 e 2022 apresentaram o maior número de publicações (4) (Tabela 2).

TABELA 4 - Publicações mais citadas.

Autores	Título	Citações
GARGIULO et al. (2018)	Dairy farmers with larger herd sizes adopt more precision dairy technologies	119
GROHER; HEITKAMPER; UMSTATTER (2020)	Digital technology adoption in livestock production with a special focus on ruminant farming	68
STEENEVELD; HOGEVEEN (2018)	Characterization of Dutch dairy farms using sensor systems for cow management	59
DREWRY; SHUTSKE; TRECHTER (2019)	Assessment of digital technology adoption and access barriers among crop, dairy and livestock producers in Wisconsin	55
NEWTON; NETTLE; PRYCE (2020)	Farming smarter with big data: Insights from the case of Australia's national dairy herd milk recording scheme	46

Fonte: Autoria própria

O Quadro 1 apresenta as tecnologias investigadas nos estudos selecionados pela revisão sistemática de literatura, conforme a classificação proposta por Moreno (2024). O conjunto de tecnologias digitais investigadas difere dependendo do sistema de produção. Em estudos em que a pecuária de corte era o foco principal destacou-se a adoção de tecnologias relacionadas à Aquisição de dados e comunicação tecnológica (por exemplo: identificação animal por radiofrequência, sensores em balanças automáticas para pesagem do animal, uso de imagens por câmeras ou drones para contagem e inventário do rebanho, dentre outros), Ciência de dados e inteligência artificial (por exemplo: uso de Big data para geração de informações para tomada de decisão - Business Intelligence), e Sistemas de informação (por exemplo: softwares ou plataformas digitais em nuvem para gerenciamento operacional e econômico da produção). Na pecuária de corte, a maior adoção concentra-se em software para gerenciar a produção, seguida de identificação animal por radiofrequência. As tecnologias com menores níveis de adoção são câmeras e drones (BOYER et al., 2024). Quanto à Ciência de dados e inteligência artificial, a probabilidade de adotar a tecnologia de big data aumenta em casos em que os produtores haviam implementado anteriormente qualquer tecnologia baseada em sensores por serem complementares (PIÑA et al., 2023). O uso de smartphone foi direcionado para a verificação de previsão meteorológica, seguida de navegação na internet e comunicação com outros produtores (DREWRY; SHUTSKE; TRECHTER, 2019; GABRIEL; GANDORFER, 2023; MARESCOTTI et al., 2021; MENDES et al., 2022; RAJCHAMAHA; MAKARARPONG, 2023).

Os estudos predominantemente em produção pecuária de leite concentraram-se nas tecnologias classificadas nas categorias de Automação, controle e robótica, e Aquisição de dados e comunicação tecnológica. Rue et al. (2020) observaram que há maior investimento em tecnologias de automação do que em tecnologias de captura de dados, sendo que a maioria deste investimento tem sido em salas de ordenha rotativa (tipo carrossel). Independentemente do tamanho do rebanho, os removedores automáticos de ordenha, software de gerenciamento e limpeza/lavagem automática de salas de ordenha foram as três tecnologias de precisão mais adotadas tanto em salas de ordenha do tipo espinha de peixe como rotativa (GARGIULO et al., 2018). As tecnologias de extração e remoção automática da sala de ordenha são apontadas com melhor custo-benefício e objetos de desejo de produtores não adotantes das tecnologias (EDWARDS;DELA RUE;JAGO, 2015). Apesar de criadores de gado leiteiro usarem mais tecnologias que facilitam a automação na ordenha, a adoção de robô na ordenha ou sistemas de ordenha automática ainda é baixa em função do alto valor inicial de investimento (GARGIULO et al., 2018; SILVI et al., 2021; VRCHOTA; PECH; SVEPESOVA, 2022). Na categoria de Aquisição de dados, há predomínio de medidores/sensores de atividade de vacas em lactação e sistemas de medição de produção de leite (ABENI; PETRERA; GALLI, 2019; BIANCHI et al., 2022; GARGIULO et al, 2018; SILVI et al., 2021). Apesar dos estudos empíricos concentrarem-se em uma ou outra tecnologia digital, ressalta-se que as tecnologias são complementares e pode haver propriedades de produção leiteira que adotam as quatro categorias tecnológicas.

QUADRO 1 - Tecnologias adotadas na bovinocultura.

Automação, Controle e Robótica	Sistemas de ordenha automática; Removedores automáticos de ordenha; Desinfecção automática pós-ordenha; Robô de ordenha; Robô de alimentação; Sistema de alimentação automática; Comedouro automático; Empurrador de alimentação automatizado; Robô de remoção de esterco; Lavagem automática de instalação; Limpador robótico; Lavagem automática de cuba; Portões automáticos; Direção com piloto automático.
Aquisição de dados e comunicação tecnológica	Sensores para detecção automática de estro e monitoramento do bem-estar animal; Sensores para monitoramento automático do comportamento alimentar e problemas metabólicos; Sensores para detecção automática de produção de leite, qualidade do leite e mastite; Sensores de comportamento dos animais; Sensores de unidades prediais ou de armazenamento de matéria prima para ração; Sensor de medição de pastagens; Tecnologias de identificação e rastreabilidade de animais; Balança automática; Câmeras; Drones.
Ciência de dados e Inteligência artificial	Registro do rebanho com aplicações em *Big Data*; *Big Data*.
Sistemas de Informação	Computador/laptop, smartphone/tablet; Acesso a internet; Mídia social; Software de registro financeiro; Software especializado para manejo de gado/confinamento; Software de formulação de dieta; Acesso a informações de mercado; Sistema de Monitoramento da produção de leite; Sistema de Monitoramento do consumo de ração; Sistema de gestão de saúde; Sistema de gestão da fertilidade do rebanho; Sistemas de posicionamento global (GPS) e Sistemas de informação geográfica (GIS); troca de e-mail com produtores; troca de e-mail com cooperativa; Modelos e aplicativos de previsão (clima, pragas); Plataformas de comunicação e negociação; Grupos digitais de compartilhamento de informações.

Fonte: Autoria própria

A decisão de adoção das tecnologias digitais na bovinocultura ocorre tanto por motivações econômicas dos agentes tomadores de decisão como por exigências governamentais. Por um lado, interesses dos produtores rurais em melhorias no sistema de produção, como a detecção de calores, a gestão do trabalho e a melhoria do bem-estar e da saúde dos animais (BIANCHI et al., 2022), ganhos econômicos maiores (ABENI; PETRERA; GALLI, 2019) e complementaridade entre tecnologias já adotadas (STEENEVELD e HOGEVEEN, 2015) foram observados como motivações para a adoção de tecnologias digitais. Por outro lado, a adoção pode ser induzida por exigências governamentais, a exemplo da obrigatoriedade do uso de dispositivos de identificação animal por radiofrequência na Nova Zelândia (EDWARDS; DELA RUE; JAGO, 2015; MARESCOTTI et al., 2021). Gabriel e Gandorfer (2023) observam ainda que a gratuidade ou o baixo custo de adoção de algumas tecnologias digitais de fácil acesso pode facilitar ou estimular a adoção de tecnologias digitais mais complexas.

Dentre os fatores determinantes da adoção de tecnologias digitais na bovinocultura, a percepção de usabilidade e utilidade da tecnologia é relevante para decisão (SILVI et al., 2021). Os autores apontam que a percepção de utilidade da tecnologia é menos evidente para produtores com menos tecnologias por não possuíam familiaridade com tecnologia, necessitando de serviços de terceiros para o uso da tecnologia.

A escala de produção, representada na maioria dos estudos pelo tamanho do rebanho, apareceu em 90% dos estudos quantitativos analisados com efeito positivo na adoção das tecnologias digitais (BOYER et al., 2024; EDWARDS; DELA RUE; JAGO, 2015; GABRIEL; GANDORFER, 2023; GARGIULO et al., 2018; GROHER; HEITKAMPER; UMSTATTER, 2020; MARESCOTTI et al., 2021; PIÑA et al., 2023; RUE et al., 2020; SILVI et al., 2021; STEENEVELD; HOGEVEEN, 2015). Produtores rurais maiores manifestam menor aversão à tecnologia (MARESCOTTI et al., 2021) e demonstram maior propensão a adoção das tecnologias digitais (GROHER; HEITKAMPER; UMSTATTER, 2020), a exemplo dos sensores para mensurar a atividade animal (BIANCHI et al., 2022; GARGIULO et al., 2018), a identificação animal por radiofrequência para monitoramento e

rastreamento de animais (BOYER et al., 2024) e as ferramentas de armazenamento e tratamento de dados - big data (PIÑA et al., 2023) no contexto da pecuária de corte, os removedores na sala de ordenha e os cochos automáticos para bezerros (GARGIULO et al., 2018) no contexto da pecuária de leite.

A idade do tomador de decisão é outro fator relevante na decisão de adoção da tecnologia digital. Gestores mais jovens são mais propensos a adotar tecnologias digitais, ao passo que seus pares mais idosos, classificados como tecnófobos por Marescotti, et al. (2021), exibem uma menor inclinação para a utilização de tecnologias digitais (DREWRY; SHUTSKE; TRECHTER, 2019; GROHER; HEITKAMPER; UMSTATTER, 2020; MARESCOTTI et al., 2021). A faixa etária mais jovem foi determinante no uso de câmeras, tecnologias de big data, sensores para a vigilância automática do comportamento alimentar e detecção automática de problemas metabólicos na produção de gado de corte, bem como na mensuração automática da produção e qualidade do leite e na detecção de mastite (BIANCHI et al., 2022; BOYER et al., 2024; PIÑA et al., 2023).

Quanto ao gênero do tomador de decisão, Drewry; Shutske; Trechter (2019) verificaram maior propensão entre as mulheres para o acesso à internet e o uso agrícola de computadores de mesa e portáteis (laptops e tablets). No entanto, esse resultado não foi corroborado por Jelinski et al. (2020) e de Groher; Heitkamper; Umstatter (2020).

O grau de escolaridade do tomador de decisão foi amplamente testado nos estudos investigados (BOYER et al., 2024, DREWRY; SHUTSKE; TRECHTER, 2019, GABRIEL; GANDORFER, 2023, MARESCOTTI et al., 2021, MENDES et al. 2022, PIÑA et al. 2023, RAJCHAMAHA; MAKARARPONG, 2023). No entanto, em apenas 50% dos estudos apresentou efeito positivo e significativo na adoção das tecnologias digitais (DREWRY; SHUTSKE; TRECHTER, 2019; MARESCOTTI et al., 2021; MENDES et al., 2022).

Na pecuária de leite as condições e o tipo das instalações da sala de ordenha influenciaram a adoção de tecnologias digitais. Instalações de sala de ordenha mais novas e em sistema rotativa (tipo carrossel) favoreceram a adoção de tecnologias de automação e novas tecnologias (EDWARDS; DELA RUE; JAGO, 2015; GARGIULO et al., 2018; RUE et al., 2020). A automação propiciou ganho de eficiência, quando comparado ao sistema de ordenha em espinha de peixe (RUE et al., 2020).

Quanto às barreiras a adoção de tecnologias digitais na bovinocultura foram observados obstáculos relacionados aos aspectos econômicos, como o elevado custo inicial do investimento, particularmente para tecnologias que exigem construções/adaptações de espaço e instalações, a relação custo-benefício e a incerteza quanto ao retorno financeiro proveniente do investimento (ABENI; PETRERA; GALLI, 2019; BIANCHI et al., 2022; BOYER et al., 2024; STEENEVELD; HOGEVEEN, 2015; MARESCOTTI et al., 2021; MAKINDE; ISLAM; WOOD, 2022). Alguns produtores pressupõe que o lapso de tempo entre a coleta de dados e as informações para tomada de decisão pode comprometer o benefício para a gestão da produção (ABENI; PETRERA; GALLI, 2019; BIANCHI et al., 2022; RUE et al., 2020). Observa-se ainda falta de clareza em como utilizar os dados coletados (BIANCHI et al., 2022, RUE et al. 2020). A ausência de conhecimento associada à complexidade acerca de algumas tecnologias digitais (BOYER et al., 2024; MAKINDE; ISLAM; WOOD, 2022) é outra barreira a adoção apontada na literatura. Boyer et al. (2024) salientam que a observação da tecnologia operando em outra propriedade rural é frequentemente mencionada pelos produtores como relevante antes de decidirem pela adoção.

Ainda, a desconfiança na privacidade dos dados armazenados em nuvem ou mesmo em ambiente local, particularmente percebido por produtores de idade mais avançada quanto às tecnologias big data, tem sido descrito em alguns estudos como obstáculos a adoção (DREWRY; SHUTSKE; TRECHTER, 2019; PIÑA et al., 2023).

A incerteza quanto a efetivação da integração da nova tecnologia com os demais softwares ou plataformas já existentes na propriedade rural (DREWRY; SHUTSKE; TRECHTER, 2019; RAJCHAMAHA; MAKARARPONG, 2023) também pode restringir a adoção.

Por fim, o acesso a internet e a estabilidade da conexão de internet como barreiras a adoção é divergente entre os estudos (BOYER et al., 2024; MARESCOTTI et al., 2021). Ressalta-se que essas pesquisas foram conduzidas em locais distintos, sendo o primeiro nos Estados Unidos e o segundo na Itália, em regiões montanhosas. Groher; Heitkamper; Umstatter (2020) apontam que regiões montanhosas possuíam um forte efeito negativo sobre a adoção de novas tecnologias quando comparadas a regiões de vale. Portanto, deve-se considerar o contexto regional ao considerar barreiras a adoção de tecnologias que demandam acesso a internet.

CONCLUSÃO

O estudo revelou que diferentes tecnologias podem ser adotadas por bovinocultores dependendo do sistema de produção. Produtores de gado de leite tendem a adotar mais tecnologias relacionadas à Automação, Controle e Robótica na sala da ordenha, e tecnologias de aquisição de dados e comunicação tecnológica voltadas para o bem-estar, reprodução e sanidade animal. Os produtores de gado de corte adotam mais tecnologias relacionadas a Aquisição de dados e comunicação tecnológica e de Sistemas de Informação. Em ambos os sistemas de produção a principal motivação é o aumento da produção.

Dentre os fatores que podem influenciar a decisão de adoção das tecnologias digitais na bovinocultura destacam-se algumas características socioeconômicas dos tomadores de decisão como a idade, o grau de escolaridade e o gênero, e algumas características da propriedade e da produção como a escala de produção, as condições das instalações e o tipo de sistema de ordenha.

Quanto às barreiras a adoção tem-se o custo inicial do investimento, a relação custo-benefício, a desconfiança quanto a privacidade dos dados e a ausência de conhecimento associado à complexidade de uso de algumas tecnologias digitais.

AGRADECIMENTOS

À Scot Consultoria pela provisão dos dados no âmbito do acordo de cooperação técnica entre Embrapa e Scot Consultoria (SAIC 2360022/0019-0). À Empresa Brasileira de Pesquisa Agropecuária (SEG 40.19.03.060.00.02.010). À Fundação de Amparo à Pesquisa do Estado de São Paulo (projeto 2023/14466-3 vinculado ao projeto 2022/02967-5).

REFERÊNCIAS

ABENI, Fabio; PETRERA, Francesca; GALLI, Andrea. A survey of Italian dairy farmers' propensity for precision livestock farming tools. Animals, v. 9, n. 5, p. 202, 2019.

Associação Brasileira das Indústrias Exportadoras de Carnes - ABIEC. Brasil Beef Report, 2023. Recuperado em 13 de janeiro de 2024, de https://www.abiec.com.br/catpub/impressos/

BARNES, Andrew P. et al. Exploring the adoption of precision agricultural technologies: A cross regional study of EU farmers. Land use policy, v. 80, p. 163-174, 2019.

BIANCHI, M. C. et al. Diffusion of precision livestock farming technologies in dairy cattle farms. animal, v. 16, n. 11, p. 100650, 2022.

BOYER, Christopher N. et al. Influence of risk and trust on beef producers' use of precision livestock farming. Computers and Electronics in Agriculture, v. 218, p. 108641, 2024.

CARRER, Marcelo José; DE SOUZA FILHO, Hildo Meirelles; BATALHA, Mário Otávio. Factors influencing the adoption of Farm Management Information Systems (FMIS) by Brazilian citrus farmers. Computers and Electronics in Agriculture, v. 138, p. 11-19, 2017.

CARRER, Marcelo José et al. Precision agriculture adoption and technical efficiency: An analysis of sugarcane farms in Brazil. Technological Forecasting and Social Change, v. 177, p. 121510, 2022.

DREWRY, Jessica L. et al. Assessment of digital technology adoption and access barriers among crop, dairy and livestock producers in Wisconsin. Computers and Electronics in Agriculture, v. 165, p. 104960, 2019.

EDWARDS, J. P.; RUE, BT Dela; JAGO, J. G. Evaluating rates of technology adoption and milking practices on New Zealand dairy farms. Animal Production Science, v. 55, n. 6, p. 702-709, 2015.

GABRIEL, Andreas; GANDORFER, Markus. Adoption of digital technologies in agriculture-an inventory in a european small-scale farming region. Precision Agriculture, v. 24, n. 1, p. 68-91, 2023.

GARGIULO, Juan I. et al. Dairy farmers with larger herd sizes adopt more precision dairy technologies. Journal of dairy science, v. 101, n. 6, p. 5466-5473, 2018.

GEROSKI, Paul A. Models of technology diffusion. Research policy, v. 29, n. 4-5, p. 603-625, 2000.

GIUA, Carlo; MATERIA, Valentina Cristiana; CAMANZI, Luca. Smart farming technologies adoption: Which factors play a role in the digital transition?. Technology in Society, v. 68, p. 101869, 2022.

GROHER, T.; HEITKÄMPER, K.; UMSTÄTTER, C. Digital technology adoption in livestock production with a special focus on ruminant farming. Animal, v. 14, n. 11, p. 2404-2413, 2020.

Instituto Brasileiro de Geografia e Estatística - IBGE. Pesquisa Pecuária Municipal. 2021. Recuperado em 13 de janeiro de 2024, de https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9107-producao-da-pecuaria-municipal.html

JELINSKI, Murray D. et al. Factors associated with the adoption of technologies by the Canadian dairy industry. The Canadian Veterinary Journal, v. 61, n. 10, p. 1065, 2020.

MAKINDE, Ayoola et al. Investigating perceptions, adoption, and use of digital technologies in the Canadian beef industry. Computers and Electronics in Agriculture, v. 198, p. 107095, 2022.

MARESCOTTI, Maria Elena et al. Smart farming in mountain areas: Investigating livestock farmers' technophobia and technophilia and their perception of innovation. Journal of Rural Studies, v. 86, p. 463-472, 2021.

MENDES, Juliana de Jesus et al. Adoption and impacts of messaging applications and participation in agricultural information-sharing groups: an empirical analysis with Brazilian farmers. Journal of Agribusiness in Developing and Emerging Economies, 2023.

MOHER, David et al. Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. International journal of surgery, v. 8, n. 5, p. 336-341, 2010.

MORENO, José C. et al. A pending task for the digitalisation of agriculture: A general framework for technologies classification in agriculture. Agricultural Systems, v. 213, p. 103794, 2024.

MORRONE, Sarah et al. Industry 4.0 and precision livestock farming (PLF): an up to date overview across animal productions. Sensors, v. 22, n. 12, p. 4319, 2022.

MOZAMBANI, Carlos Ivan et al. Adoption of precision agriculture technologies by sugarcane farmers in the state of São Paulo, Brazil. Precision Agriculture, p. 1-23, 2023.

NEWTON, Joanna E.; NETTLE, Ruth; PRYCE, Jennie E. Farming smarter with big data: Insights from the case of Australia's national dairy herd milk recording scheme. Agricultural Systems, v. 181, p. 102811, 2020.

PIÑA, Rolando et al. Big data technology adoption in beef production. Smart Agricultural Technology, v. 5, p. 100235, 2023.

R Core Team (2022). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL https://www.R-project.org/.

RAJCHAMAHA, Kittichai; MAKARARPONG, Davids. Dairy Farmers' Intention to Use High-Precision Area-Level Weather Warning Technology in Dairy Farms in Thailand Through an Application on Mobile Phones. International Journal of Interactive Mobile Technologies, v. 17, n. 18, 2023.

RUE, BT Dela et al. New Zealand dairy farmers preference investments in automation technology over decision-support technology. Animal Production Science, v. 60, n. 1, p. 133-137, 2019.

SOUZA FILHO, Hildo Meirelles et al. Condicionantes da adoção de inovações tecnológicas na agricultura. Cadernos de Ciência & Tecnologia, v. 28, n. 1, p. 223-255, 2011.

SILVI, Rebeca et al. Adoption of precision technologies by Brazilian dairy farms: The farmer's perception. Animals, v. 11, n. 12, p. 3488, 2021.

STEENEVELD, W.; HOGEVEEN, H. Characterization of Dutch dairy farms using sensor systems for cow management. Journal of Dairy Science, v. 98, n. 1, p. 709-717, 2015.

TEY, Yeong Sheng; BRINDAL, Mark. Factors influencing the adoption of precision agricultural technologies: a review for policy implications. Precision agriculture, v. 13, p. 713-730, 2012.

TEY, Yeong Sheng; BRINDAL, Mark. A meta-analysis of factors driving the adoption of precision agriculture. Precision Agriculture, v. 23, n. 2, p. 353-372, 2022.

VINHOLIS, Marcela de Mello Brandão; CARRER, Marcelo José; SOUZA FILHO, Hildo Meirelles de. Adoption of beef cattle traceability at farm level in São Paulo State, Brazil. Ciência Rural, v. 47, p. e20160759, 2017.

VRCHOTA, Jaroslav; PECH, Martin; ?VEPE?OVÁ, Ivona. Precision Agriculture Technologies for Crop and Livestock Production in the Czech Republic. Agriculture, v. 12, n. 8, p. 1080, 2022.

VARIAÇÃO DO CUSTO NA SEMEADURA DE SOJA EM FUNÇÃO DO USO DE ZONAS DE MANEJO

FELIPE CARNACINI [1]; ANDREY DE OLIVEIRA RIBEIRO LIMA [2]; MURILO APARECIDO VOLTARELLI [3]; CARLA SEGATTO STRINI PAIXÃO [4]

[1]Bolsista de Mestrado . Rod. João Leme dos Santos, Km 110, Sorocaba - SP, 18052-780. UNIVERSIDADE FEDERAL DE SÃO CARLOS - CAMPUS SOROCABA; [2]ESTUDANTE DE GRADUAÇÃO. Rodovia Lauri Simões de Barros, km 12 - SP-189 - Aracaçu, Buri - SP, 18290-000. UNIVERSIDADE FEDERAL DE SÃO CARLOS - CAMPUS LAGOA DO SINO; [3]DOCENTE. Rodovia Lauri Simões de Barros, km 12 - SP-189 - Aracaçu, Buri - SP, 18290-000. UNIVERSIDADE FEDERAL DE SÃO CARLOS - CAMPUS LAGOA DO SINO; [4]DOCENTE. Rodovia Senador José Ermírio de Moraes, 1425 - Jardim Constantino Matucci, Sorocaba - SP, 18085-784. FACULDADE DE ENGENHARIA DE SOROCABA

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A colheita da safra do estado de São Paulo 2023/2024 cresceu em 10%, quando comparada a safra do ano anterior do estado. O aumento de qualidade nas operações pode ter sucesso a partir das boas práticas de manejo e semeadura. Nesse sentido, o objetivo do trabalho foi prescrever a recomendação de adubo para a semeadura da cultura de soja em taxa variável, a partir dos atributos do solo. O georreferenciamento de pontos foi realizado a partir da utilização do software QGIS®, com 6 pontos aleatórios, compondo uma grade de 1:10 (uma amostra para cada 10 hectares) em uma área total de aproximadamente 58 ha. Após a amostragem de solo, houve a elaboração dos mapas de argila (%) e teor de Fósforo (mg dm $^{-3}$), pelo método do inverso do quadrado da distância (IDW). *Machine learning* foi responsável pela sobreposição dos dados, gerando as zonas de manejo por meio do agrupamento entre a camada vetorial de argila e do teor de fósforo. Para que houvesse diminuição nos custos operacionais do sojicultor, em solo com condições mais favoráveis para o desenvolvimento da planta, foi prescrito 260 kg/ha, enquanto a prescrição de 300 kg/ha, foi para solo menos desfavoráveis, assegurando desta forma bom desenvolvimento e buscando alta produtividade. As diferentes zonas de manejo implementadas, reduziram em R$ 7.750,00 (133,62 R$/ha), quando comparadas com a adubação em taxa fixa.

PALAVRAS-CHAVE: *Glycine max* L. Merril; Custos de produção; Adubação

ABSTRACT

The 2023/2024 harvest grew in the state of São Paulo by 10% when compared to the previous years's harvest. Increasing the quality of operations can be sucessful based on good management and sowing practices. In this sense, the objective of this study was to prescribe the recommendation of fertilizer for soybean crops at a variable rate, based on soil attributes. The georeferencing of point was based on the use of QGIS® software, with 6 point random points, composing a 1:10 grid (one sample for every 10 hectares). After soil sampling, clay (%) and phosphorus content (mg dm $^{-3}$) maps were prepared using the inverse square of distance (IDW) method. Machine learning was responsible for overlapping the data, generating the management zones by grouping the clay vector layer and the phosphorus content. In order to reduce the soybean farmer's operating costs, in soils with more favorable conditions for the plant development, 260 kg/ha was prescribed, while the prescription of 300 kg/ha was prescribed in less unfavorable soils, thus ensuring good development and high productivity. The different diferente management zones implemented reduced R$ 7.750,00 (133,62 R$/ha), when compared to fixed-rate fertilization.

KEYWORDS: ;;

INTRODUÇÃO

A cultura da soja *(Glycine max* L. Merril) desempenha um papel de grande destaque econômico em função de seu potencial produtivo e do valor nutricional, sendo a comodity mais exportada atualmente. Segundo a CONAB (2024), essa cultura no país teve uma área plantada de 45.295,6 milhões/ha, com produção de 162.420,9 milhões de t e havendo uma produtividade de 3.586 kg/ha. Com o avanço das tecnologias no campo, como mecanização e produção em larga escala, o cultivo da terra passou a ser tratada de maneira uniforme. A prescrição de adubo, baseia-se na quantidade média de fertilidade, sendo aplicado uniformente na área produtiva. Entretanto, áreas que necessitam de mais adubação, por serem menos férteis, não recebem essa quantidade necessária, e áreas que são mais produtivas, recebem em excesso. Desta forma, o produtor, tem desperdícios em áreas desnecessárias e menos produtividade (TIEPPO et al., 2007). A adoção de boas práticas de manejo com utilização de ferramentas da Agricultura de Precisão (AP), auxiliam na redução de custos para o produtor rural e o melhor gerenciamento de sua propriedade. Ao criar um sistema de gerenciamento agrícola baseado na variabilidade espacial da unidade produtiva, tem sua base na geoestatística (BRASIL, 2013). É um modelo probabilístico, fundamentada na aleatoriedade dos dados para avaliar correlação espacial entre dados, com a utilização do inverso do quadrado da distância (IDW) e Krigagem, para auxiliar na construção dos mapas de variabilidade (VIERA et al., 2008). O estudo da variabilidade espacial, auxilia em solos com diferentes práticas agrícolas e para estimar quais as respostas das propriedades do solo em função das determinadas práticas de manejo (OVALLES e REY, 1994). A utilização dos mesmos, auxilia na demarcação das zonas de manejo, as quais apresentam mínima variabilidade espacial e são classificadas por parâmetros como: textura, produtividade, etc. (MANN et al., 2010). Rodrigues Jr et al. (2011) afirmam que a adoção das zonas de manejo facilita a aplicação à taxa variada. Bazzi et al. (2012) informaram que o emprego das zonas de manejo, viabilizou a aplicação de insumos localizados e Alba et al. (2012) reduziram os custos operacionais e elevando a capacidade produtiva em função das unidades de maior rendimento dentro do talhão. Desta forma, com a adoção das zonas de manejo, pode auxiliar na redução de custos ao produtor, objetivou-se recomendar doses de adubo em taxa variável na semeadura de soja em função de zonas de manejo com alto e baixo potencial do solo, com a proposta de aumentar o lucro do produtor.

OBJETIVOS

Objetivou-se recomendar doses de insumos em taxa variável na semeadura de soja em função de zonas de manejo com alto e baixo potencial do solo, visando diminuir os custos com adubação

MATERIAL E MÉTODOS

O experimento foi realizado em uma área agrícola na região sudoeste de São Paulo, com coordenadas geodésicas próximas a 23°36'10"S e longitude 48°31'58", na qual possuía 58 hectares com irrigação por aspersão via pivô central (FIGURA 1). O clima do local é Cwa, de acordo com a classificação de Koppen, possuindo características de clima temperado úmido com inverno seco e verão quente. As temperaturas anuais oscilam entre 14 °C a 27 °C, com precipitação média anual enquadrando-se na faixa requerida pela cultura (de 1.000 a 1.500mm), havendo alta adaptabilidade à região. A recomendação de adubo de plantio 04-30-10 (N-P-K) para a determinada área do estudo em taxa fixa foi de 300 kg/ha, com um preço por tonelada aproximado de R$ 5.200,00. Foram georreferenciados seis pontos de forma aleatória pelo software QGIS®(FIGURA 1), as quais tiveram amostras de solo em uma profundidade de 0-20cm coletadas.



FIGURA 1. Pontos aleatórios definidos pelo software QGIS®. Fonte: Autoria Própria (2022)

RESULTADOS E DISCUSSÃO

Pela análise dos dados da TABELA 1, é possível identificar que o ponto tem menor porcentagem de argila e quantidade de Fósforo em comparação aos outros pontos.

ID	Lat	Long	P (mg/dm³)	Argila (%)
1	-48.77282748063200302	-23.5593367677339991	28	70
2	-48.77173848352799723	-23.56293240778699882	33	75
3	-48.7742546565679973	-23.5635643221529989	30	72,4
4	-48.77539607768400032	-23.56150419466899848	34	74,3
5	-48.76920485626399682	-23.56159601082899968	31	75,8
6	-48.77289366912999924	-23.56586505117099861	39	74,5

Com a aplicação regular de adubos, é possível aumentar os teores de P, impulsionado pelo efeito residual. Entretanto, em solos ricos em argila, é necessário que a aplicação seja elevada. Para melhor visualização das quantidades de P, tanto quanto de Argila, foram elaborados o mapa de Argila (Figura 2a) e de Fósforo, com diferentes cores para identificar as quantidades espacializadas (FIGURA 2b).

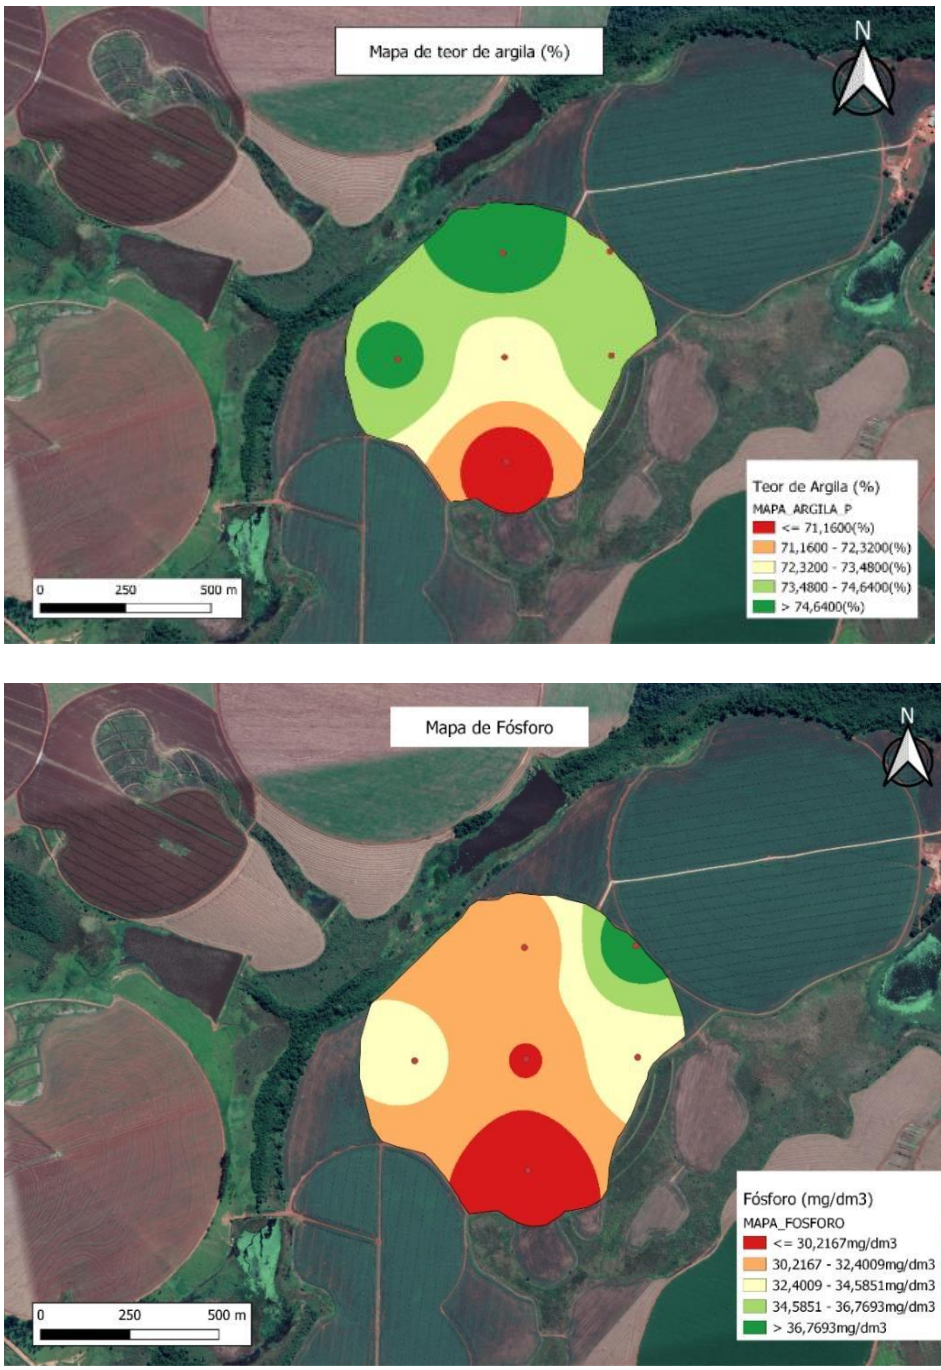


FIGURA 2. Mapa do teor de Argila elaborado no software QGIS®(a) e Mapa do teor de P elaborado no software QGIS®(b). Fonte: Autoria Própria (2022)

CONCLUSÃO

Definiu-se a recomendação da quantidade de adubo necessários para as zonas de baixo e alto potencial produtivo, sendo que 260 kg/ha, prescritos para a zona de alto potencial e de 300 kg/ha para a de baixo potencial. Com o comparativo por meio da análise financeira, houve a geração de uma economia com adubo de R$ 7.750,00 (133,62 R$/ha), com a adoção da zona de manejo em relação a taxa fixa.

AGRADECIMENTOS

Agradeço a CAPES por disponibilizar bolsa financeira no período do Mestrado na UFSCar-Sorocaba.

REFERÊNCIAS

BAZZI, C.L.; SOUZA, E.G.; KONOPATSKI, M.R.; OPAZO, M.A.U.; RODRIGUES,F.A. **Unidades de Manejo em Pomar de Peras.** In: Congresso Brasileiro de Agricultura de Precisão. Ribeirão Preto, 2012. BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. **Agricultura de precisão**. Secretária de Desenvolvimento Agropecuário e Cooperativismo. Brasília. 2013. 36 p.

BVAN, R.; CANTARELLA,H.; QUAGGIO,J.A.; FURLANI, A.M.C. **Recomendações de adubação e calagem para o Estado de São Paulo**. 2ª.ed. Campinas: Instituto Agronômico de Campinas/ Fundação IAC; 1997. (Boletim técnico, 100).

CAMBARDELLA, C.A et al. Field-scale variability of soil Properties in Central Iowa soils. Soil **Science Society of America Journal**, v.58, n.5, p. 1501-1511, 1994.

CONAB - Companhia Nacional de Abastecimento. Acompanhamento da safra Brasileira de grãos na safra 2023/24. **Boletim da Safra de Grãos**. Brasília. 2024.

MANN, K.K.; SCHUMANN, A.W.; OBREZA, T.A. **Delineating productivity zones in a citrus grove using citrus producting, tree growth and temporally stable soil data**. Precision Agriculture, Secaucus, v.12,p.457-472, 2010.

MAZZINI, P. L. F.; SCHETTINI, C. A. F. **Avaliação de metodologias de interpolação espacial aplicadas a dados hidrográficos costeiros quase-sinóticos.** Braz. J. Aquat. Sci. Technol., v. 13, n. 1, p. 53-64, 2009.

TIEPPO, R.C.; SOUZA, E.G.; URIBE OPAZO, M.A.; SILVEIRA, J.C.M. 2007**. Avaliação de diferentes interpoladores na geração de mapas temáticos da produtividade de soja em agricultura de precisão**. In: IV Simpósio Internacional de Agricultura de Precisão, Viçosa, 2007. *Anais*... IV SIAP, Viçosa, outubro.

OVALLES, F.; REY, J. **Variabilidad interna de unidades de fertilidad en suelos de la depresión del Lago de Valencia**. Agronomia Tropicale, Maracay, v.44, n.1, p.41-65, 1994.

VIEIRA, S. R.; XAVIER, M. A.; GREGO, C. R**. Aplicações de geoestatística em pesquisas com cana-de-açúcar**. In: DINARDO-MIRANDA, L. L.; VASCONCELOS, A. C. M.;LANDELL, M. G. A. (Ed.). Cana de açúcar. Ribeirão Preto: Instituto Agronômico, 2008. p. 839-852

FATORES QUE DIFERENCIAM OS ADOTANTES DE TECNOLOGIAS DIGITAIS EM CONFINAMENTOS DE BOVINOS DE CORTE NO BRASIL

GUSTAVO DA SILVA GONÇALVES [1]; LETÍCIA CAROLINE DA SILVA DAVID [1]; MARCELO JOSÉ CARRER [2]; MARCELA DE MELLO BRANDÃO VINHOLIS [3]; HILDO MEIRELLES DE SOUZA FILHO [2]

[1]Bolsista. Rod. Washington Luiz, km 235, São Carlos - SP, 13565-905. Departamento de Engenharia de Produção, Universidade Federal de São Carlos; [2]Docente. Rod. Washington Luiz, km 235, São Carlos - SP, 13565-905. Departamento de Engenharia de Produção, Universidade Federal de São Carlos; [3]Pesquisadora. Rod. Washington Luiz, km 234, São Carlos - SP, 13560-970. Empresa Brasileira de Pesquisa Agropecuária

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A adoção de tecnologias digitais na pecuária possibilita ganhos de eficiência e melhorias no bem-estar animal. Um conjunto de fatores pode influenciar positiva ou negativamente a decisão de adoção destas tecnologias pelos produtores. Este estudo tem por objetivo identificar as principais características que discriminam os adotantes dos não adotantes de identificação eletrônica de animais e software de gestão operacional de confinamentos de bovinos de corte no Brasil. Essas duas tecnologias apresentam importantes complementaridades e a adoção conjunta tende a trazer ganhos de sinergia no gerenciamento dos confinamentos. Microdados primários de 130 confinamentos dispersos em regiões produtoras de gado de corte no Brasil foram analisados por meio de estatísticas descritivas e teste de hipóteses. Os resultados sugerem que as variáveis relacionadas à escala de produção e qualificação da mão de obra estão associadas à adoção das tecnologias digitais investigadas. Estes resultados têm implicações para o setor, como o desenho de estratégias para incluir produtores de menor escala na transformação digital e para capacitação de mão de obra no uso de tecnologias digitais.

PALAVRAS-CHAVE: identificação animal; software; bovinos

ABSTRACT

The adoption of digital precision technologies in beef cattle feedlots allows for efficiency gains and animal welfare. A set of factors can have positive or negative influence on farmers' decisions on technology adoption. This study aims to identify the main characteristics that differentiate adopters from non-adopters of electronic identification of bovine associated with management software in beef cattle feedlots in Brazil. Data from 130 Brazilian feedlots were analyzed through descriptive statistics and hypothesis tests (chi-square and t-student). The results suggest that variables related to production scale and qualified labor are associated with the adoption of digital technologies. These results have implications for the sector, such as the development of strategies for the inclusion of small farmers in digital transformation and the training of labor to handle digital technologies.

KEYWORDS: confinamento; adoção de tecnologia

INTRODUÇÃO

A pesquisa e a adoção de tecnologias de precisão e digital na produção agropecuária brasileira têm recebido estímulos por meio de políticas, a exemplo da Política Nacional de Incentivo à Agricultura e Pecuária de Precisão no Brasil (BRASIL, 2022). O objetivo é aumentar a eficiência no uso dos recursos e insumos, reduzir os custos e aumentar a produtividade e a lucratividade, garantindo sustentabilidade ambiental, social e econômica. A adoção dessas tecnologias na pecuária possibilita

também ganhos no bem-estar animal. O manejo dos animais pode ser melhorado como a partir da coleta e análise de um conjunto de dados do ambiente e do animal em tempo real, o que pode resultar em decisões mais assertivas, melhorias nos coeficientes zootécnicos e ganhos de eficiência da produção (CARRER et al., 2023), além de avanços na condição físico-funcional e afetiva dos animais (BANHANZI et al., 2012; BERCKMANS, 2017).

A aplicação de tecnologias da informação e comunicação (TIC), tais como a Internet das Coisas (IoT), dispositivos eletrônicos e sistemas de processamento de dados, têm ocupado espaço notório em diversas atividades econômicas, incluindo a produção pecuária intensiva em sistemas de confinamento (FAROOQ, 2022). A conexão entre sensores aliados à internet e plataformas digitais capazes de armazenar dados em nuvem e analisar dados por meio de algoritmos pode trazer soluções para desafios complexos (DINEVA; ATANASOVA, 2021; STOYANOV et al., 2018). Para Alshehri (2023), é esperado que o uso destas tecnologias na pecuária promova maior eficiência no processo de alimentação dos animais, melhore aspectos de bem-estar animal e de sustentabilidade da produção, bem como promova o desenvolvimento de automações que minimizem a interferência humana no manejo operacional da fazenda.

A identificação individual eletrônica dos animais é uma ferramenta importante na pecuária de precisão. Em geral, o dispositivo de identificação por radiofrequência (RFID) é associado a outros sensores (ARSLAN et al., 2014; SHEN et al., 2019), a exemplo de sensores para pesagem dos animais ou de consumo de alimentos. A radiofrequência pode estar embutida em brincos de identificação, colares, ou dispositivos administrados de maneira subcutânea ou oralmente. Os dados registrados por estas tecnologias podem ser traduzidos em informações úteis para a gestão do confinamento, monitorando características relacionadas à saúde, bem-estar, nutrição e reprodução (HERLIN et al., 2021). Por sua vez, o uso de softwares especializados na análise dos dados permite aos tomadores de decisão melhores estratégias de planejamento e controle da produção, melhorando a alocação e o uso dos recursos da produção (MADURANGA; ABEYSEKERA, 2020; CARRER et al., 2023). Ainda, o uso sistemático das ferramentas permite o monitoramento das atividades operacionais em tempo real e a previsão de eventos produtivos e dificuldades econômicas associadas (WOLFERT, 2017).

Investigar o perfil dos adotantes destas tecnologias e as barreiras associadas à adoção é relevante para o desenvolvimento de novos produtos e para a definição de melhores estratégias de transferência da tecnologia. Estudos empíricos em adoção de tecnologias agropecuárias indicam algumas características do produtor e da produção capazes de influenciar a decisão de adoção da tecnologia, prioritariamente aquelas associadas ao capital humano e escala de produção, como a experiência do produtor, o grau de escolaridade, a participação em grupos formalmente organizados e o tamanho do rebanho, dentre outras (MICHELS et al., 2020; CARRER, 2022). Este estudo adiciona novos achados a essa literatura, ao identificar os principais fatores que discriminam adotantes de não adotantes de identificação eletrônica de animais e software de gestão operacional de confinamentos de bovinos de corte no Brasil.

OBJETIVOS

Identificar as principais características que discriminam os adotantes dos não adotantes de identificação eletrônica de animais e software de gestão operacional de confinamentos de bovinos de corte no Brasil.

MATERIAL E MÉTODOS

Os microdados primários utilizados neste artigo são oriundos da pesquisa Expedição Confina Brasil, realizada pela empresa Scot Consultoria no ano de 2023. Foram selecionadas propriedades rurais que praticam a engorda de bovinos em sistemas de confinamento. O questionário contempla questões

relacionadas às características do gestor do confinamento, características da estrutura do confinamento e da produção, incluindo o rebanho, práticas de gestão e uso de tecnologias. Foram realizadas 179 entrevistas com gestores de confinamentos em diversas regiões produtoras de bovinos de corte no Brasil. Contudo, alguns produtores não responderam todas as questões apresentadas. Neste estudo, foram utilizados os dados de 130 confinamentos que informaram sobre o uso de tecnologias digitais, neste caso, a identificação eletrônica do animal e o software para gestão operacional do confinamento.

A Tabela 1 descreve as variáveis do estudo. A variável de interesse refere-se à adoção, ou não adoção, de identificação eletrônica do animal e software para gestão operacional do rebanho (variável binária com dois grupos amostrais, adotantes de tecnologia digital =1 e não adotantes=0). Assume-se que essas duas tecnologias são complementares. A identificação individual eletrônica é importante para coletar dados, enquanto os softwares organizam, armazenam e processam esses dados. Assim, o processo de tomada de decisão do produtor tende a ser mais assertivo com a adoção em conjunto dessas tecnologias. As demais variáveis de análise contemplam as características do gestor e do confinamento. Foram calculadas as estatísticas descritivas (média, desvio padrão e frequência) para cada grupo amostral (adotantes e não adotantes) e, em seguida, foram realizados os testes de hipóteses para diferenças.

O teste qui-quadrado de Pearson foi aplicado para verificar a associação, ou não, entre os grupos amostrais (adotantes=1 e não adotantes=0) e as variáveis qualitativas (PEARSON, 1900). O teste t de Student foi aplicado no caso das variáveis quantitativas para verificar se as médias dos dois grupos amostrais são estatisticamente diferentes (STUDENT, 1908).

TABELA 1. Descrição das variáveis do estudo.

Variáveis	**Descrição**
Adoção de tecnologia	Variável binária que assume valor igual a 1 se o confinamento adota identificação eletrônica do animal e software para gestão operacional do rebanho, 0 caso contrário.
Características do gestor do confinamento:	
Escolaridade do gestor	Variável binária que assume valor 1 se o gestor possui nível superior ou pós-graduação, 0 caso contrário.
Experiência	Número de anos com experiência em confinamento.
Fonte de renda	Variável binária que assume valor igual a 1 se a pecuária é a principal fonte de renda do produtor, 0 caso contrário.
Acesso a crédito	Variável binária que assume valor 1 se nos últimos 3 anos acessou algum crédito para financiar as atividades do confinamento, 0 caso contrário.
Capacidade de inovação	Capacidade de inovação do produtor em função da resposta em escala Likert (1, discordo totalmente; 2, discordo; 3, indiferente; 4, concordo; 5, concordo totalmente) à declaração: "Eu gosto de testar novas tecnologias no confinamento?".
Aversão ao risco	Grau de aversão ao risco do produtor em função da resposta em escala Likert (1, discordo totalmente; 2, discordo; 3, indiferente; 4, concordo; 5, concordo totalmente) à declaração: "Quando se trata de negócios, eu prefiro a opção mais segura, mesmo sabendo que eu posso ganhar menos".
Características do confinamento:	
Modelo de gestão	Variável binária que assume valor igual a 1 se o confinamento é gerenciado por um grupo comercial, 0 caso contrário (gestão familiar ou individual/autônomo).
Capacidade estática	Capacidade estática do confinamento em 2023, em número de animais.
Animais confinados	Número de animais confinados no ano de 2023.
Produtividade da mão de obra	Número de animais confinados por colaborador.
Escolaridade de colaboradores	Número de colaboradores com ensino superior completo.
Restrição de mão de obra	Variável binária que assume valor igual a 1 se a contratação e manutenção da mão de obra é uma grande dificuldade no confinamento, 0 caso contrário.

RESULTADOS E DISCUSSÃO

A Tabela 2 apresenta as estatísticas descritivas dos grupos de adotantes e não adotantes de identificação individual eletrônica dos animais e software para gestão operacional do confinamento. O resultado dos testes de hipóteses (p-valor) demonstra a significância estatística das diferenças de médias/frequências das variáveis para os dois grupos.

TABELA 2. Estatísticas descritivas e teste de hipótese: fatores que diferenciam adotantes e não adotantes das tecnologias digitais.

	Adotantes			Não adotantes			
Variáveis	**N**	**Média**	**D.P.**	**N**	**Média**	**D.P.**	**p-valor**
Características do gestor do confinamento:							
Escolaridade do gestor	64	0,87	0,33	61	0,85	0,36	0,713
Experiência *	64	12,77	8,42	63	16,13	13,74	0,100
Fonte de renda	65	0,35	0,48	63	0,33	0,48	0,807
Acesso a crédito	57	0,54	0,50	56	0,50	0,51	0,641
Capacidade de inovação	64	4,34	1,03	58	4,17	1,27	0,673
Aversão ao risco	64	3,97	1,1	57	3,82	1,1	0,289
Características do confinamento:							
Modelo de gestão	66	0,21	0,41	64	0,11	0,32	0,112
Capacidade estática ***	66	11.372,55	15.559,64	64	4.333,44	4.991,89	0,001
Animais confinados ***	66	19.974,17	32.131,45	63	7.187,94	8.661,32	0,003
Escolaridade de colaboradores ***	61	3,72	4,31	62	1,77	2,98	0,004
Produtividade da mão de obra	64	1.107,89	1.316,46	63	846,75	642,08	0,158
Restrição de mão de obra	61	0,74	0,44	62	0,71	0,46	0,728

Nota: O número de observações (N) é diferente entre as variáveis em função de "*missing*" na base de dados (dados ausentes).

*** para p<0,01; ** para p<0,05; * para p<0,10.

Algumas características da estrutura e da gestão do confinamento mostraram-se estatisticamente significantes para discriminar os adotantes dos não adotantes de tecnologias digitais (identificação individual + software). A capacidade estática média dos confinamentos do grupo de adotantes é de 11.372,55 animais, sendo aproximadamente 2,6 vezes maior do que a média da capacidade estática do grupo de não adotantes (4.333,44 animais). Como era de se esperar, o grupo de adotantes confina, em média, um número maior de animais. Na média, esse grupo confinou cerca de 2,7 vezes mais animais em 2023 do que os não adotantes (19.974,17 contra 7.187,4 animais confinados, respectivamente). Essa diferença pode ser explicada pela complexidade de gestão exigida por confinamentos que recebem maiores quantidades de gado, tanto no controle quanto no monitoramento. O mesmo resultado também foi observado por Gargiulo et al. (2018) em propriedades rurais leiteiras, onde pecuaristas que operavam maiores rebanhos adotaram uma maior quantidade de tecnologias de precisão. Estes resultados corroboram também outros achados em que variáveis relacionadas a escala de produção estão positivamente associadas a adoção de tecnologias digitais em diferentes atividades agropecuárias (CARRER et al., 2022; GROHER et al., 2020; MOZAMBANI et al., 2023; VINHOLIS et al., 2017). Os dados mostram também que, na média, o grupo de adotantes operou em 2023 com menor capacidade ociosa do que o grupo de não adotantes (média de 1,76 giro de animais confinados, contra 1,66, respectivamente). Próximo do nível de significância estatística de 10%, observa-se que 21% dos confinamentos do grupo dos adotantes são administrados por grupos comerciais, contra 10% no grupo dos não adotantes. De forma geral, a gestão por meio de grupos comerciais tende a ter uma relação comercial mais próxima de frigoríficos, com uma rotatividade e volume de animais confinados maior, o que torna a adoção de tecnologias digitais mais atrativa.

Observa-se também que, na média, o número de colaboradores com ensino superior completo é aproximadamente 2,1 vezes maior em confinamentos do grupo de adotantes das tecnologias digitais, quando comparado ao grupo dos não adotantes (3,72 contra 1,77 colaboradores com ensino superior, respectivamente). Este resultado pode ser um indicativo da necessidade de mão de obra mais

qualificada para a utilização de algumas tecnologias digitais associadas ao uso de informações para a gestão do confinamento. Outrossim, percebeu-se que a produtividade média parcial da mão de obra nos confinamentos dos adotantes foi superior à dos não adotantes (1.107,89 x 46,75 animais por colaborador). Apesar de essa diferença só ser estatisticamente significante ao nível 16%, há um interessante indicativo de maior qualificação associada à maior produtividade do trabalho nos confinamentos que utilizam as tecnologias digitais investigadas. Riddel e Song (2017) verificaram relação positiva e estatisticamente significante entre a educação formal de colaboradores e a adoção de tecnologias digitais que favorecem a execução de tarefas mais complexas. Esse achado reforça a importância do investimento em recursos humanos para promover a difusão das tecnologias 4.0 na pecuária.

O grupo dos não adotantes apresentou, na média, mais tempo de experiência em confinamento do que o grupo de adotantes. Uma possível explicação pode estar associada à maior autoconfiança dos produtores com mais tempo de experiência, que tendem a não perceber tanto valor nas tecnologias digitais para gerenciamento, o que pode reduzir a utilidade esperada na adoção.

As demais variáveis de análise não foram estatisticamente significativas para diferenciar os adotantes dos não adotantes das tecnologias digitais investigadas. No entanto, algumas estatísticas descritivas sinalizam aspectos relacionados à mão de obra nos confinamentos. Observa-se que há dificuldade na contratação e manutenção de mão de obra. Em ambos os grupos, a proporção de produtores que apontaram essa dificuldade supera os 70%. Ainda, o grau de escolaridade dos gestores de confinamentos da amostra é elevado. Em ambos os grupos cerca de 90% dos pecuaristas possuem nível superior ou pós-graduação.

CONCLUSÃO

Este estudo objetivou identificar fatores capazes de distinguir pecuaristas adotantes e não adotantes de identificação eletrônica de animais e software para a gestão de confinamentos. Dados primários de 130 confinamentos foram analisados por meio de estatísticas descritivas e testes de hipóteses. Os resultados indicaram que variáveis associadas a escala de produção e qualificação da mão de obra são importantes para a adoção de tecnologias digitais, são elas: (i) maior capacidade estática do confinamento, (ii) maior número de animais confinados em 2023, e (iii) maior quantidade de colaboradores com ensino superior completo. Estes resultados têm implicações para o setor, como o desenvolvimento de estratégias para evitar a exclusão de pecuaristas de menor escala de produção da transformação digital no campo e estratégias para a capacitação da mão de obra em tecnologias digitais.

AGRADECIMENTOS

À Scot Consultoria e Embrapa (acordo de cooperação técnica SAIC 2360022/0019-0). À Fundação de Amparo à Pesquisa do Estado de São Paulo (projeto 2023/16008-2 vinculado ao projeto 2022/02967-5).

REFERÊNCIAS

ALSHEHRI, M. Blockchain-assisted internet of things framework in smart livestock farming. **Internet of Things**, v. 22, p. 100739, 2023.

ARSLAN, A. C.; AKAR, M.; ALAGÖZ, F. 3D cow identification in cattle farms. In: **2014 22nd Signal Processing and Communications Applications Conference (SIU)**. IEEE, p. 1347-1350, 2014.

BANHAZI, T. M. et al. Precision livestock farming: an international review of scientific and commercial aspects. **International Journal of Agricultural and Biological Engineering**, v. 5, n. 3, p. 1-9, 2012.

BERCKMANS, D. General introduction to precision livestock farming. **Animal Frontiers**, v. 7, n. 1, p. 6-11, 2017.

BRASIL. Lei nº 14.475, de 13 de dezembro de 2022. Política Nacional de Incentivo à Agricultura e Pecuária de Precisão. **Diário Oficial da União**: Seção 1, Brasília, DF, p. 1, 14 dez. 2022.

CARRER, M. J.; SOUZA FILHO, H. M.; VINHOLIS, M. M. B.; MOZAMBINI, C. I. Precision agriculture adoption and technical efficiency: An analysis of sugarcane farms in Brazil. **Technological Forecasting and Social Change**, v. 177, p. 121510, 2022.

CARRER, M. J.; TORRES, E. A. M.; VINHOLIS, M.M.B.; SOUZA FILHO, H. M.; EUSEBIO, G. S. Impactos da adoção de softwares de gestão financeira e operacional na eficiência técnica de confinamentos de bovinos de corte no Brasil. Anais do 51º Encontro Nacional de Economia, Associação Nacional dos Programas de Pós-graduação em Economia (ANPEC), Rio de Janeiro - RJ, 2023.

DINEVA, K.; ATANASOVA, T. Design of scalable IoT architecture based on AWS for smart livestock. **Animals**, v. 11, n. 9, p. 2697, 2021.

FAROOQ, M. S.; SOHAIL, O. O.; ABID, A.; RASHEED, S. A survey on the role of IoT in agriculture for the implementation of smart livestock environment. **IEEE Access**, v. 10, p. 9483-9505, 2022.

GARGIULO, J. I.; EASTWOOD, C. R.; GARCIA, S. C.; LYONS, N. A.. Dairy farmers with larger herd sizes adopt more precision dairy technologies. **Journal of dairy science**, v. 101, n. 6, p. 5466-5473, 2018.

GROHER, T.; HEITKÄMPER, K.; UMSTÄTTER, C. Digital technology adoption in livestock production with a special focus on ruminant farming. **Animal**, v. 14, n. 11, p. 2404-2413, 2020.

HERLIN, A.; BRUNBERG, E.; HULTGREN, J.; HÖGBERG, N.; RYDBERG, A.; SKARIN, A. Animal welfare implications of digital tools for monitoring and management of cattle and sheep on pasture. **Animals**, v. 11, n. 3, p. 829, 2021.

MADURANGA, M. W. P.; ABEYSEKERA, R. Machine learning applications in IoT based agriculture and smart farming: A review. **Int. J. Eng. Appl. Sci. Technol**, v. 4, n. 12, p. 24-27, 2020.

MICHELS, M.; FECKE, W.; FEIL, J. H.; MUSSHOFF, O.; PIGISCH, J.; KRONE, S.l. Smartphone adoption and use in agriculture: empirical evidence from Germany. **Precision Agriculture**, v. 21, p. 403-425, 2020.

MOZAMBANI, C. I., SOUZA FILHO, H. M., VINHOLIS, M. M. B., CARRER, M. J. Adoption of precision agriculture technologies by sugarcane farmers in the state of São Paulo, Brazil. **Precision Agriculture**, v. 24, n. 5, p. 1813-1835, 2023.

PEARSON, Karl. **On the criterion that a given system of deviations from the probable in the case of a correlated system of variables is such that it can be reasonbly supposed to have arisen from random sampling**. 1900.

RIDDELL, W. C.; SONG, X. The role of education in technology use and adoption: Evidence from the Canadian workplace and employee survey. **ILR Review**, v. 70, n. 5, p. 1219-1253, 2017.

SHEN, W. et al. Individual identification of dairy cows based on convolutional neural networks. **Multimedia Tools and Applications**, v. 79, p. 14711-14724, 2020.

STOYANOV, S.; OROZOVA, D.; POPCHEV, I. Internet of things water monitoring for a smart seaside city. In: 2018 20th International Symposium on Electrical Apparatus and Technologies (SIELA). **IEEE,** p. 1-3, 2018.

STUDENT. The probable error of a mean. **Biometrika**, p. 1-25, 1908.

VINHOLIS, M. M. B.; CARRER, M. J.; SOUZA FILHO, H. M. Adoption of beef cattle traceability at farm level in São Paulo State, Brazil. **Ciência Rural**, v. 47, p. e20160759, 2017.

WOLFERT, S.; GE, L., VERDOUW, C., BOGAARDT, M. J.. Big data in smart farming-a review. **Agricultural systems**, v. 153, p. 69-80, 2017.

ESPACIALIZAÇÃO DO PREJUÍZO DAS FALHAS NA FILEIRA DE CANA-DE-AÇÚCAR

Eudocio Rafael Otavio da Silva [1]; Ricardo Canal Filho [1]; Marcelo Chan Fu Wei [1]; José Paulo Molin [2]
[1]Doutorando em Engenharia de Sistemas Agrícolas. Av. Pádua Dias, 235 - Agronomia, Piracicaba - SP, 13418-900. Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo; [2]Professor Titular. Av. Pádua Dias, 235 - Agronomia, Piracicaba - SP, 13418-900. Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
A falha na fileira compromete o potencial produtivo e impacta o retorno econômico do canavial. O objetivo deste estudo foi avaliar espacialmente as falhas de cana-de-açúcar e estimar os custos financeiros associados a elas. Em um canavial comercial, foram obtidos dados de colheita mecanizada e de reconstituição das fileiras e distribuição das falhas nas fileiras, coletados por veículo aéreo não tripulado (UAV). Foi estimada a produtividade e produção não obtida decorrente das falhas e os custos financeiros a ela associados: custo econômico e custo de oportunidade da falha. A análise de regressão foi utilizada para descrever o efeito causal da falha na produção não obtida e seu custo de oportunidade. As maiores ocorrências de falhas foram de 0,58 a 1,00 m no intervalo de produtividade não alcançada de 75,00 a 100,00 Mg ha^{-1}. Falhas de mesmo comprimento resultam em diferentes produtividades não obtidas, dependendo do potencial produtivo onde a falha ocorre. Devido a isso, nem sempre o talhão mais falhado é o de maior estimativa de produção não obtida devido às falhas, indicando que a tomada de decisão para a gestão canavieira baseada apenas na porcentagem de falhas é limitada. O custo econômico da falha é diretamente proporcional ao comprimento da mesma, independentes de sua localização no talhão. Enquanto o custo de oportunidade da falha não apenas varia conforme seu comprimento, mas também de acordo com o potencial produtivo da região em que se encontra.

PALAVRAS-CHAVE: custo de oportunidade; mapa de produtividade; veículo aéreo não tripulado

ABSTRACT
Row gap compromises the productive potential and impacts the economic return of the sugarcane plantation. The aim of this study was to spatially evaluate sugarcane row gaps and estimate the financial costs associated with them. In a commercial sugarcane plantation, mechanized harvesting and row reconstruction data and the distribution of gaps in the rows were collected by an unmanned aerial vehicle (UAV). The yield and production not obtained as a result of the row gaps and the financial costs associated with them were estimated: economic cost and opportunity cost of the gap. Regression analysis was used to describe the causal effect of gap on unearned production and its opportunity cost. The highest occurrences of gaps were from 0.58 to 1.00 m in the unachieved yield range of 75.00 to 100.00 Mg ha^{-1}. Gaps of the same length result in different unachieved yields, depending on the production potential where the gap occurs. Because of this, the most failed plot is not always the one with the highest estimate of production not obtained due to gaps, indicating that decision-making for sugarcane management based solely on the percentage of gaps is limited. The economic cost of gap is directly proportional to the length of the gap, regardless of its location in the field. While the opportunity cost of gap not only varies according to its length, but also according to the productive potential of the region in which it is located.

KEYWORDS: ;

INTRODUÇÃO

A cana-de-açúcar é uma gramínea semi-perene, com ciclos de duração de 5 a 7 anos em regiões tropicais (SANTOS et al., 2015), sendo a longevidade do canavial uma das variáveis mais importantes a serem considerada na sua gestão. Ela é negativamente afetada pela má qualidade do preparo de solo, plantio, colheita e outras operações envolvidas no cultivo da cultura, gerando falhas na fileira de cana, o que afeta a produtividade e culmina em impactos econômicos negativos na produção (AMORIM et al., 2022). A falha na fileira de cana corresponde ao local onde deveria existir uma planta emergida no espaçamento entre plantas desejado. Logo, essas falhas comprometem o aproveitamento do potencial produtivo da cana na fileira e impactam o retorno econômico. Desde a década de 1980, as pesquisas relacionadas às falhas na fileira da cana têm se concentrado em: i) definir o potencial de diferentes métodos de mensuração de falhas, sejam eles manuais (STOLF, 1986; CAVALCANTI et al., 2023), utilizando Veículos Aéreos Não Tripulados (UAV) (LUNA & LOBO, 2016; SOUZA, 2017; BARBOSA JÚNIOR et al., 2021; ROCHA et al., 2022), ou sensores fotoelétricos e ultrassônicos embarcados em máquinas (MOLIN & VEIGA, 2016; MALDANER et al., 2021); ii) identificar padrões espaciais na distribuição das falhas, como sua ocorrência na curvatura da fileira (PENEDO et al., 2018); iii) identificar o(s) estágio(s) fenológico(s) com maior aptidão à identificação de falhas (OLIVEIRA et al., 2023); e iv) correlacionar as falhas na fileira com dados de produtividade em baixa (STOLF et al., 1991) e alta resolução espacial (MALDANER et al., 2024). Observa-se que há poucos estudos que relacionam os dados de falhas com dados de produtividade em alta resolução espacial e, principalmente, ausência de estimativa de produção não obtida e os custos associados à ocorrência dessas falhas no canavial. Embora o mapeamento de falhas na fileira forneça suporte aos gestores para tomada de decisões sobre replantio e aplicação de insumos agrícolas, como adubos, herbicidas e pesticidas (BARBOSA JÚNIOR et al., 2021), o conhecimento da quantidade de falhas por si só pode não ser suficiente para orientar essas decisões na fazenda, pois é um dado que precisa estar associado à outras variáveis para a compreensão de sua participação no decréscimo da produção. Assim, a estimativa de custos e a produtividade não obtida devido a essas falhas apresentam potencial para orientar a tomada de decisões sobre a realização de gestão localizada, total ou parcialmente no campo, garantindo a otimização da rentabilidade.

OBJETIVOS

O objetivo deste estudo foi avaliar espacialmente as falhas de cana-de-açúcar e estimar os custos financeiros associados a elas.

MATERIAL E MÉTODOS

Área de estudo e coleta de dados

O estudo foi conduzido em um canavial comercial composto por 10 talhões que totalizam 205,70 hectares, localizado no município de Mirassolândia (20°37'01" S, 49°27'50" O), no estado de São Paulo, Brasil. O clima na região de estudo é tropical de inverno seco, Aw de acordo com a classificação climática de Köppen-Geiger. A variedade RB966928 foi plantada mecanicamente com espaçamento entre fileiras de 1,50 m em 2019 e colhida em 2021 (terceiro corte). Três camadas de dados foram utilizadas neste estudo: dados produtividade obtidos da colhedora de cana, reconstituição das fileiras e distribuição das falhas nas fileiras, ambas obtidas pela geometria de linhas coletadas por UAV. Os dados de produtividade foram obtidos por colhedora de cana, que cortam e processam uma única fileira por vez, embarcada com receptor de Sistema Global de Navegação por Satélite (GNSS). Os dados de produtividade foram obtidos em uma frequência de 0,20 Hz. O mapeamento da produtividade foi realizado com um sistema comercial (Solinftec, Araçatuba, São Paulo, Brasil) que utiliza as variações da pressão de propulsão no picador da colhedora para a redistribuição da produção da cana no campo (MALDANER et al., 2022). Posteriormente, estes dados foram filtrados utilizando uma filtragem automática de dados baseado na estatística da mediana e janela deslizante (ZENG et al., 2023) (Tabela 1).

TABELA 1. Caracterização do conjunto de dados de produtividade filtrados.

Talhão	Área (ha)	nº pontos	Densidade (pontos ha^{-1})	Média prod. (Mg ha^{-1})	Classe do solo[a]
1	8,69	2875	330,84	81,61	Latossolo Vermelho álico
2	30,08	10158	337,70	83,03	Latossolo Vermelho álico
3	22,23	8398	377,78	89,34	Latossolo Vermelho álico
4	23,79	8794	369,65	80,04	Latossolo Vermelho álico
5	23,03	7509	326,05	76,94	Latossolo Vermelho álico
6	32,17	13398	416,48	92,56	Latossolo Vermelho distrófico
7	12,88	4365	338,90	86,25	Latossolo Vermelho álico
8	9,04	3437	380,20	93,38	Latossolo Vermelho álico
9	15,71	6787	432,02	90,18	Latossolo Vermelho álico
10	27,10	11698	431,66	88,85	Latossolo Vermelho álico

a: Santos et al. (2018); nº pontos: número de pontos total no talhão; Média prod.: média da produtividade.

Os dados das fileiras e das falhas na fileira da cana foram coletados por uma empresa de serviços contratada para essa finalidade, que forneceu o conjunto de dados de cada talhão, contendo: nº de falhas, nº de fileiras de plantio, comprimento linear de fileiras (CLL) e comprimento linear de falhas (CLF). O método de coleta desses dados utilizou um UAV, modelo eBee, embarcado com sensor RGB S.O.D.A, que possui resolução espacial de 0,03 m. O voo foi realizado com base na altura das plantas, quando atingiram o crescimento entre 0,60 a 1,20 m no início da safra, na fase de perfilhamento da cana-soca. Posteriormente, foi gerado o mosaico de imagens que permitiu a reconstituição das geometrias das linhas (linhas de plantio) correspondentes às fileiras de cana-de-açúcar. Em seguida, utilizando como critério a identificação de espaçamentos entre plantas superiores ou iguais a 0,58 m, foram identificadas as falhas na fileira da cana (Tabela 2).

TABELA 2. Caracterização do conjunto de dados de falhas e das fileiras de cana-de-açúcar obtidos por Veículo Aéreo Não Tripulado (UAV).

Talhão	nº falhas	Méd. CLF	Soma CLF	nº fileiras	Méd. CLL	Soma CLL
		m			m	
1	04.179	1,68	07.014,97	0230	252,15	057.995,64
2	25.516	1,49	38.023,29	1006	196,27	197.442,93
3	11.213	1,52	17.084,81	0634	232,85	147.625,95
4	17.064	1,51	25.784,84	0596	265,68	158.342,70
5	09.287	1,36	12.613,32	0693	221,09	153.215,82

6	08.217	1,30	10.707,65	0379	543,33	205.922,71
7	04.883	1,42	06.908,10	0578	144,51	083.524,39
8	04.790	1,21	05.790,98	0409	148,77	060.845,93
9	06.041	1,34	08.092,33	0497	199,85	099.324,46
10	08.436	1,30	10.984,12	0691	255,54	176.581,42

nº falhas: número de falhas; Méd. CLF: média do comprimento linear das falhas; Soma CLF: Soma do comprimento linear das falhas; nº fileiras: número de fileiras de cana; Méd. CLL: média do comprimento linear das fileiras; Soma CLL: Soma do comprimento linear das fileiras.

Estimativa de produtividade e de produção não obtidas decorrente das falhas

Em ambiente de Sistema de Informação Geográfica (SIG) do programa QGIS v. 3.22.10, foi gerada uma grade de pontos espaçadas a 0,58 m sob as fileiras de cana reconstituídas. Baseado nos vizinhos mais próximos, essa grade de pontos utilizou os valores de produtividade da camada de produtividade, garantindo que cada ponto da grade estivesse associado a um dado (MALDANER et al., 2024). Para estimar a produtividade não obtida decorrente das falhas foram utilizados dois conjuntos de dados: produtividade e falhas. Incorporando estes dados ao projeto, foi criada uma camada de *buffer* para as falhas (zona retangular que compreende a região circundante da falha, na direção da fileira), obtendo os dados de produtividade média por falhas dentro do *buffer*. Isto permitiu a obtenção da estimativa de produtividade não obtida decorrentes das falhas (Y_f) (Figura 1).

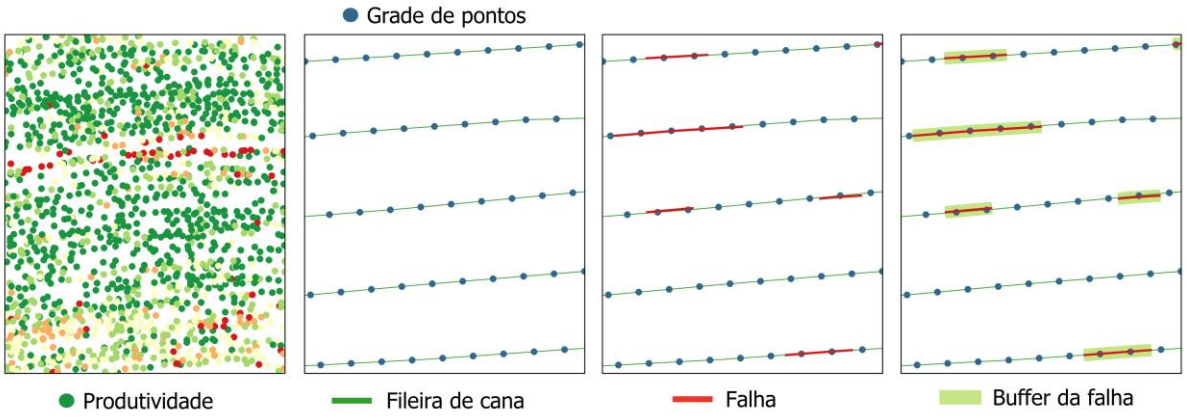


FIGURA 1. Etapas para a obtenção da estimativa da produtividade não obtida decorrentes das falhas na fileira da cana.

A estimativa da produção de cana não obtida em cada falha existente no talhão foi obtida utilizando os dados de produtividade não obtidas decorrente das falhas, comprimento da falha e extensão da fileira de cana do talhão, como exibida na equação 1.

$$P_f = (Y_f \times Área) \times \left(\frac{CLF_i}{CLL}\right) \quad \text{Eq. (1)}$$

em que: P_f - produção de biomassa de cana não obtida decorrente da falha em determinado local *i* (Mg); Y_f - produtividade de cana não obtida decorrente da falha em determinado local *i* (Mg ha^{-1}); Área - área do talhão (ha); CLF_i - comprimento linear da falha em determinado local *i* (m); CLL - comprimento linear da fileira de cana existente no talhão (m).

Análise econômica

Dois custos relacionados às falhas foram calculados: custo da falha e custo de oportunidade. O custo da falha está relacionado à sua existência no canavial, ou seja, o simples fato da falha existir na fileira da cana e não ser considerada nas operações agrícolas ao longo da safra corrobora em custos na produção. Este custo está associado ao CLF, custo de arrendamento e tratos culturais. O custo de tratos culturais em cana-soca são os investimentos em manejos realizados na cultura visando obter bons desempenhos de produtividade. Ou seja, este custo é o quanto o produtor investe financeiramente em tratos no canavial visando garantir a produtividade da cultura, sendo influenciado pelo momento econômico do setor (GOMES & BAJAY, 2017). O arrendamento está diretamente ligado à região em que está inserido o canavial. A taxa de arrendamento é influenciada pelo preço histórico da terra, fertilidade do solo, topografia, distância da unidade industrial, tamanho da área, acessibilidade, entre outros fatores (GOMES & BAJAY, 2017). A equação 2 indica o cálculo do custo econômico das falhas (CEF).

$$CEF = CLF_i \times (C_{arrendamento} + C_{tratos\ culturais}) \quad \text{Eq. (2)}$$

em que: CEF - custo econômico da falha (R$); CLF - comprimento linear da falha (m) no canavial em determinado local *i*, referente a um talhão; $C_{arrendamento}$ - custo de arrendamento (R$ metro linear^{-1}); $C_{tratos\ culturais}$ - custo de tratos culturais (R$ metro linear^{-1});

Os valores de custo da falha foram posteriormente transformados em custo da falha por hectare. O segundo custo é o de oportunidade, em que por deixar de produzir cana em determinados locais devido às falhas, deixa-se de ganhar economicamente (equação 3). O custo de oportunidade refere-se ao que se deixa de ganhar ao optar por determinado investimento em detrimento de outros disponíveis (HIRSCHFELD, 1998). No cenário do presente estudo, representa os ganhos potenciais não obtidos ao escolher por um investimento em vez de outro.

$$COF = P_f \times Valor\ do\ TCH \quad \text{Eq. (3)}$$

em que: COF - custo de oportunidade da falha (R$); P_f - produção de biomassa de cana não obtida decorrente da falha em determinado local *i* (Mg); TCH - tonelada de cana por hectare.

A análise econômica foi baseada em dados obtidos do setor sucroenergético, exibidos na Tabela 3. Outros custos relacionados às operações, como custos operacionais, não foram considerados neste estudo.

TABELA 3. Dados de custos utilizados para a análise econômica de falhas na fileira de cana.

Custo	Variáveis	R$ ha^{-1}	R$ metro linear^{-1}
Custo da falha	Tratos culturais[a]	2.953,89	0,45
	Arrendamento[a]	2.377,00	0,36
Custo de oportunidade	1 TCH[b]	128,00	-

a: dados obtidos da Associação Rural dos Fornecedores e Plantadores de Cana do Vale do Paranapanema (ASSOCANA, 2023); b: dado obtido do Conselho dos Produtores de Cana de Açúcar, Açúcar e Etanol do Estado de São Paulo (CONSECANA, 2023); TCH: tonelada de cana por hectare.

Estatísticas descritivas e de frequência foram realizadas para os dados obtidos. A análise de regressão foi realizada para descrever o efeito causal do comprimento das falhas na P_f e no CEF para cada talhão, sendo obtido o p-valor a 99% de confiança ($p<0,01$) e coeficiente de determinação (R^2). As análises desenvolvidas neste estudo foram realizadas por meio do ambiente virtual *JupyterLab*, utilizando a linguagem de programação *Python* v. 3.10.5 (KLUYVER et al., 2016).

RESULTADOS E DISCUSSÃO

A ocorrência de Y_f e de CLF no canavial é exibida como histogramas (Figura 2A) e em classes (Figura 2B). Para o comprimento das falhas (histograma superior do eixo x), observou-se maior frequência em comprimentos menores, com menor ocorrência para os maiores comprimentos. Isso é esperado, pois a probabilidade de ocorrer gemas não brotadas consecutivamente em uma extensão maior na fileira de cana é menor do que em uma extensão menor (STOLF, 1986). Esse comportamento resulta em uma curva de distribuição exponencial decrescente com o aumento do tamanho da falha, corroborando com experimentações de Stolf (1986). Os valores de CLF variaram de 0,58 a 27,50 m, com maior ocorrência entre 0,58 a 1,50 m (valores compreendidos até o terceiro quartil), padrão verificado em outros estudos, como o de Molin e Veiga (2016) e Cavalcanti et al. (2023) em canaviais sob outros cenários localizados nas regiões Sudeste e Nordeste do Brasil, respectivamente. A estimativa de Y_f exibiu um histograma com distribuição assimétrica em relação à média, com amplitudes de valores de 40,00 a 178,00 Mg ha^{-1} e valor médio de 78,00 Mg ha^{-1}. Isto indica que é necessário analisar mais do que apenas a média dos dados.

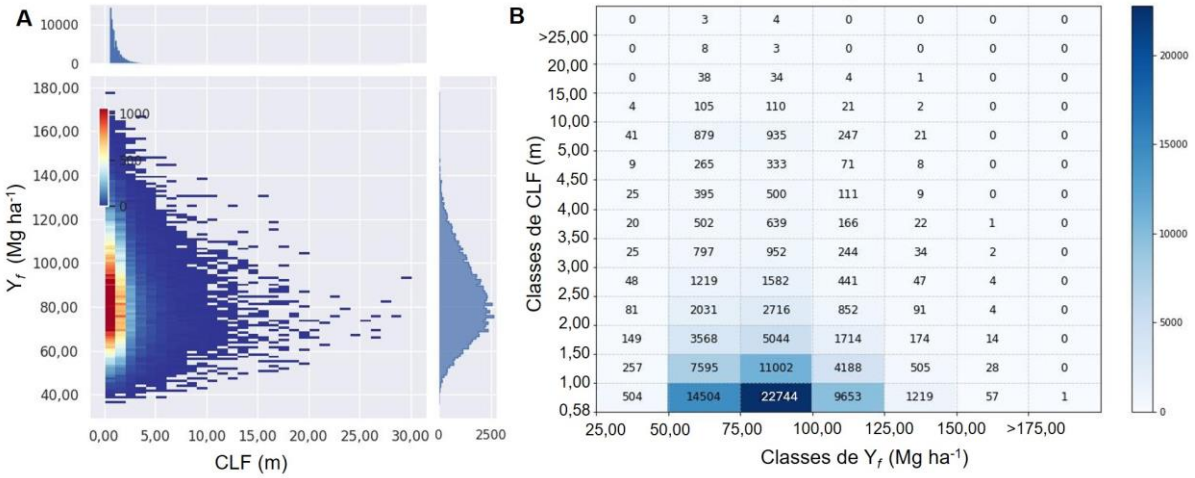


FIGURA 2. Distribuição de frequência da estimativa de produtividade não obtida decorrente das falhas no canavial, para os 10 talhões. Distribuição por histograma (A) e distribuição da ocorrência por classes (B). Os números em cada célula em B correspondem às ocorrências de determinado intervalo de CLF em relação à Y_f. CLF: comprimento linear da falha. Y_f: produtividade de cana não obtida decorrente da falha.

Na Figura 2B foi observado que a maior ocorrência de falhas compreende o intervalo de 0,58 a 1,00 m, com estimativas de Y_f variando de 75,00 a 100,00 Mg ha^{-1}. Neste mesmo intervalo de CLF, foram identificadas diferentes estimativas de produtividade não obtida. Por exemplo, constatou-se uma única ocorrência de Y_f superior a 175,00 Mg ha^{-1}. Verificou-se esse padrão de comportamento para os outros intervalos de comprimentos de falhas e de Y_f no canavial, que proporciona robustez aos valores. Logo, observou-se que o mesmo CLF pode resultar em diferentes valores de Y_f. Os talhões possuem variações de porcentagem de falhas de 5,20 a 19,26%, com somas de falhas que variam de 0,87 a 5,70 ha, totalizando 21,45 ha de falhas no canavial. Esses valores fornecem um panorama do desenvolvimento da cana-soca na fileira e da dimensão de espaçamento entre plantas onde não ocorre produção. Entretanto, tais dados são insuficientes para embasar decisões de gestão na fazenda relacionadas às falhas, pois não estão associados à outras variáveis, como dados de produtividade da cana. A produtividade média dos talhões variou de 76,94 a 93,38 Mg ha^{-1}, valores superiores à média nacional para essa safra, que foi de 70,36 Mg ha^{-1} (CONAB, 2022). No entanto, essa variável pode estar limitando a produção da cultura, como observado na Tabela 4.

TABELA 4. Estatísticas de produtividade, comprimento de falhas e estimativa da produção de cana não obtida decorrente das falhas.

Talhão	Prod. Média (Mg ha^{-1})	*f* (%)	Soma *f* (ha)	P_f (Mg)			
				Min	Max	Med	Soma
1	81,61	12,10	1,05	0,004	0,286	0,020	84,80
2	83,03	19,26	5,70	0,003	0,312	0,018	467,41
3	89,34	11,57	2,56	0,002	0,178	0,011	118,66
4	80,04	16,28	3,87	0,004	0,328	0,018	305,55
5	76,94	8,23	1,89	0,004	0,204	0,015	138,80
6	92,56	5,20	1,61	0,004	0,325	0,019	158,09
7	86,25	8,27	1,04	0,001	0,128	0,007	34,35
8	93,38	9,52	0,87	0,004	0,180	0,017	83,51
9	90,18	8,15	1,21	0,001	0,143	0,008	45,75
10	88,85	6,22	1,65	0,001	0,380	0,016	133,91
Total	-	-	21,45	-	-	-	1.570,82

Prod. Média: Produtividade média; P_f: Produção de biomassa de cana não obtida decorrente da falha em determinado local *i*; *f*: Comprimento de falhas; *f*(%): Porcentagem de falhas; Min: Mínimo; Max: Máximo; Med: Média.

Os valores mínimos de P_f nos talhões variaram de 0,001 a 0,004 Mg, apresentando uma amplitude de dados que alcançou valores máximos de 0,128 a 0,328 Mg. A soma dos valores de P_f indica que deixou de ser produzido cerca de 1570,82 Mg de cana na colheita do canavial em 2021. O talhão 2 possui a maior soma de comprimento de falhas e a maior soma de P_f. No entanto, o talhão 7, que possui o menor valor de soma de P_f, não é o menor em soma de comprimentos de falhas; a menor soma foi verificada para o talhão 8 (conforme mostrado na Figura 3). Isso ocorre porque a estimativa de P_f considera não apenas o tamanho da falha, mas também dados associados à produtividade do local onde a falha está localizada no talhão.

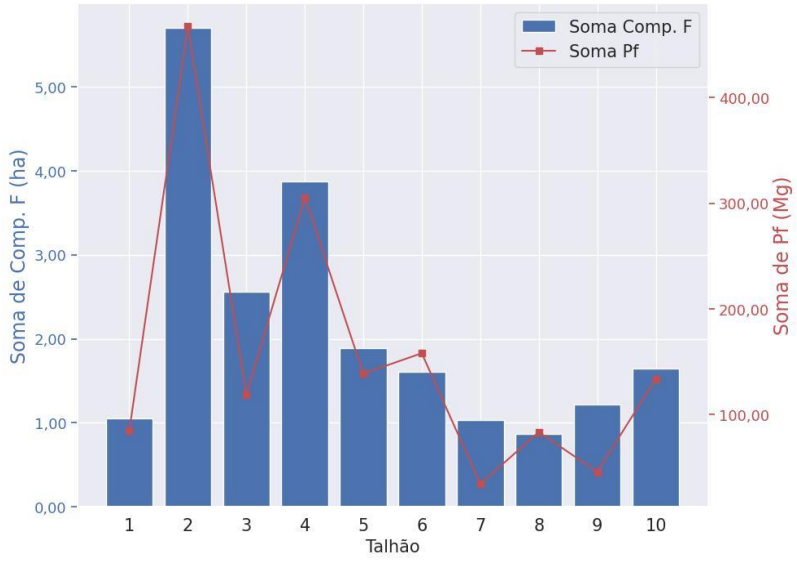


FIGURA 3. Soma de comprimentos de falhas e da estimativa de produção não obtida decorrente das falhas na fileira da cana. Comp. F: Comprimento de falhas. P_f: Produção de cana não obtida decorrente das falhas.

Ainda, verificou-se que os talhões 1 e 7 possuem valores próximos na soma dos comprimentos de falhas, sendo 1,05 e 1,04 ha, respectivamente. Portanto, se um gestor esperava estimativas de produção não obtida sem considerar a relação entre falhas e produtividade no local, esperava-se obter valores igualmente próximos. No entanto, observou-se que a soma de P_f foi de 84,80 Mg para o talhão 1 e 34,35 Mg para o talhão 7, indicando que a produtividade associada a cada local influenciou esse resultado. Os custos econômicos e de oportunidade relacionados às falhas são mostrados na Tabela 5.

TABELA 5. Análise econômica das falhas na fileira em cana-soca.

Talhão	CEF		COF	
	Soma (R$)	Soma (R$ ha-¹)	Soma (R$)	Soma (R$ ha-¹)
1	5.682,16	654,17	10,853,89	1249,58
2	30.799,17	1023,84	59,829,12	1988,87
3	13.838,71	622,44	15,188,35	683,14
4	20.885,65	877,84	39,110,53	1643,85
5	10.216,83	443,65	17,766,78	771,50
6	8.673,33	269,64	20,235,14	629,08
7	5.595,56	434,51	4,396,29	341,38
8	4.690,76	499,18	10,688,64	1137,45
9	6.554,78	417,45	5,856,26	372,96
10	8.897,09	328,37	17,134,08	632,37
Total	115.834,03	-	201.059,07	-

CEF: Custo econômico da falha; COF: Custo de oportunidade da falha.

Para os valores nos cenários propostos, a soma do CEF para todos os talhões foi de R$ 115.834, 03, indicando que na colheita desta safra, este valor foi perdido economicamente. Isto porque as operações agrícolas foram realizadas ao longo da safra e insumos agrícolas, por exemplo, foram aplicados em locais sem plantas. Este custo mostra a necessidade do uso de métodos de identificação de falhas em tempo real, seja por sensores, algo já explorado na literatura (MALDANER et al., 2021; MOLIN & VEIGA, 2016), ou pelo desenvolvimento de novas tecnologias que permitam a identificação das falhas na fileira e otimize a aplicação de insumos, uma abordagem com potencial de utilização. Foi verificado, pela totalização do COF dos talhões, que se deixou de ganhar R$ 201.059,07. Esse valor representa o potencial de ganhos que não foram alcançados nesta colheita devido às falhas na fileira. Observou-se que o talhão 2 é o canavial mais falhado e o de maior CEF entre os deste estudo, enquanto o talhão 6 possui os menores valores para estas variáveis. Como o CEF é relacionado ao tamanho da falha, este custo econômico é impactado diretamente por estes comprimentos, independentes de sua localização no talhão. Logo, para toda a fazenda, falhas de mesmo comprimento apresentaram os mesmos valores de CEF. Enquanto o COF não apenas varia

conforme o comprimento da falha, mas também de acordo com o potencial produtivo da região em que se encontra. Por exemplo, uma falha de 3,09 m possui o mesmo custo econômico (CEF) em todo o canavial, porém os ganhos econômicos potenciais (custo de oportunidade, COF) seriam maiores ou menores dependendo de sua localização no canavial. Estas informações são relevantes para o analista de dados e gestor da fazenda, pois a tomada de decisão de operações no campo poderá ser feita com base no potencial econômico dos talhões. As regressões lineares para os talhões na Figura 4 apoiam estes resultados, sendo observado que mesmos valores de CLF podem variar quanto aos valores de P_f (A) e COF (B) na mesma fazenda.

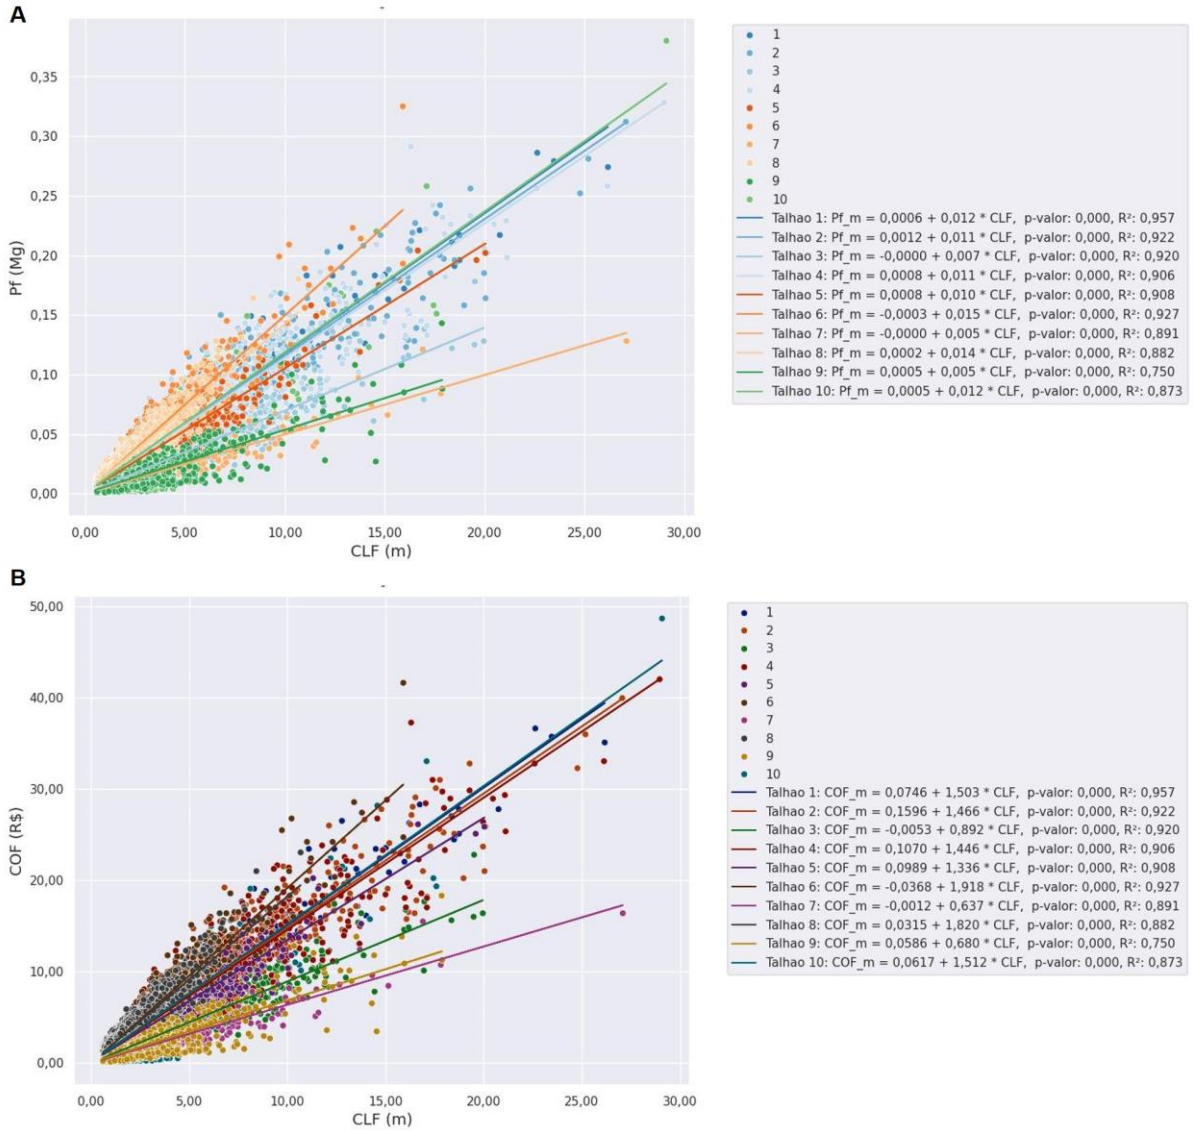


FIGURA 4. Produção de cana não obtida (A) e custo de oportunidade (B) em relação ao comprimento de falhas para os talhões. R^2: coeficiente de determinação. p-valor: Teste t significativo ao nível de confiança de 99% (p?<0,01). CLF: comprimento linear da falha. P_f: Produção de cana não obtida decorrente da falha. COF: Custo de oportunidade da falha. m: modelo de regressão.

Nas equações de regressão linear dos talhões é mostrado que cada talhão possui um comportamento em relação à não obtenção de produção de cana (A) e o quanto se deixa de ganhar economicamente devido às falhas (B), mesmo sendo talhões vizinhos da mesma variedade, corte e sendo gerenciados da mesma maneira. É evidente que existem outros fatores, como fatores de formação do solo, tráfego e orientação das fileiras, que podem ser os responsáveis por essa diferenciação expressa nas modelagens, embora não sejam abordados aqui. Os resultados estatisticamente significativos

demonstram que quanto maior o comprimento da falha, maiores são os valores de P_f e COF, resultando em diferentes impactos para cada talhão. O coeficiente β1 (função da regressão linear, $y = \beta0 \pm \beta1x$) indica a magnitude de P_f ou COF (y) à medida que se aumenta o valor de CLF (x). Para cada talhão, uma falha de 2 m de comprimento (x) representa diferentes estimativas de P_f, (y), em que cada talhão apresenta uma distribuição de valores de produtividade distinta. Esse padrão de comportamento nestes talhões também é observado para o COF. Embora tenham sido observadas modelagens semelhantes em determinados talhões, essas não são representativas para toda a fazenda, destacando a necessidade de modelagem local para uma estimativa acurada dessas variáveis no talhão. Foi notado que nem sempre essa relação linear das variáveis ocorreu em todos os pontos, sendo encontrados em um mesmo talhão valores de CLF iguais, mas com valores de P_f e COF diferentes. Isto ocorre porque a Y_f associada à falha pode ser diferente (Figura 5), indicando mais uma vez que a associação com o potencial produtivo local ocorre não apenas entre talhões, mas entre fileiras e entre plantas em um mesmo talhão. Portanto, a equação obtida para cada talhão satisfaz a relação causal do que deixou de ser produzido e de ser ganho economicamente no talhão decorrente da falha, mas há limitações quanto aos modelos lineares que precisam ser explorados futuramente. Na Figura 5, o talhão 6 é tomado como exemplo. Foram verificadas produtividades que variam de 42,51 a 165,04 Mg ha^{-1}, comprimentos de falhas de 0,58 a 15,91 m e estimativas de P_f que variam de 0,004 a 0,325 Mg. Observa-se pela caracterização espacial dessas variáveis que as falhas com os maiores valores de P_f, destacadas em vermelho escuro na Figura 5C, estão associadas aos maiores comprimentos de falhas (em amarelo na Figura 5A) e aos maiores valores de Y_f (em vermelho na Figura 5B), embora estejam localizadas em diferentes regiões do talhão. Percebe-se que os maiores valores de P_f estão correlacionados aos maiores valores de Y_f. No entanto, nem sempre as falhas de maior comprimento apresentaram os maiores valores de P_f. Ao sobrepor o mapa de produtividade sobre essas camadas na análise (Figura 5D), identificou-se que a variabilidade espacial da produtividade precisa ser levada em consideração. Isso indica que falhas de mesmo comprimento possuem diferentes estimativas de produção não obtida, dependendo da sua localização e do potencial produtivo da cana no campo. Resultados similares foram verificados em Maldaner et al. (2024), em que, ao longo três safras, foi observada influência do espaçamento entre plantas na produtividade da cana, com comportamentos distintos para os diferentes potenciais produtivos.

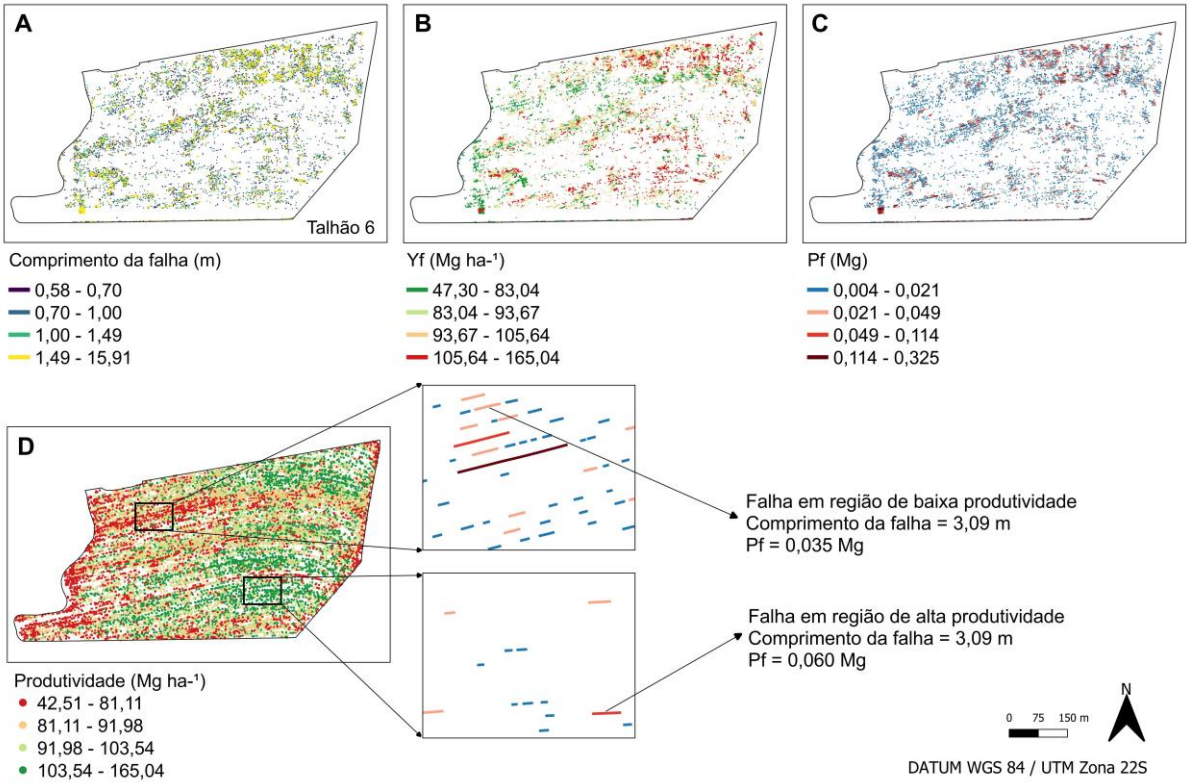


FIGURA 5. Caracterização espacial do comprimento de falhas (A), produtividade (Y_f) e produção (P_f) não obtida decorrente das falhas (B, C) e produtividade da cana (D) no talhão 6.

Os fatores que levam à diferenciação de potenciais produtivos estão relacionados ao relevo, ao tráfego irregular sob a cana-soca, condição de umidade do solo durante o tráfego, fenômeno de curvatura da fileira (PENEDO et al., 2018), pragas, compactação do solo (CAVALCANTI et al., 2023). Isto ressalta a importância do mapa de produtividade na tomada de decisão para a gestão canavieira, contribuindo em decisões como a aplicação otimizada de insumos, identificação de talhões para a reforma e locais na lavoura adequadas para o replantio de falhas, práticas onerosas ao setor canavieiro. Observa-se que a tomada de decisão para a gestão canavieira baseada apenas na porcentagem de falhas é limitada, apesar de ser uma prática comum realizada por usinas e por fornecedores independentes de cana. Como exposto, a porcentagem de falhas numericamente por si só é um dado que necessita de apoio de outras variáveis, como potenciais perdas de produção e dados de custos, para o gerenciamento de insumos ou sobre decisões de reforma ou replantio em canaviais. Neste estudo, foi constatado que as falhas não apresentaram relações óbvias quanto à sua expressão no canavial. Conforme evidenciado em estudos anteriores, em menores espaçamentos entre plantas na fileira, até determinado ponto, ocorre um aumento da produtividade, embora ocasione, devido ao efeito da competição, redução do peso dos colmos, o que é compensado pelo número deles (efeito da população) (CASAGRANDE, 1991; MALDANER et al., 2024). Além disso, estudos apontam maior ocorrência de falhas em espaçamentos reduzidos entre as fileiras e em curvaturas dentro das fileiras (PENEDO et al., 2018). Ainda, é necessário investigar se as plantas vizinhas aos locais com falhas dentro da fileira são afetadas por efeitos de compensação de biomassa devido à maior disponibilidade de luz, hídrica e de recursos no solo. Logo, em estudos futuros, seria pertinente avaliar os custos das falhas considerando esses efeitos na lavoura. Os resultados apontam para uma relação de causa e efeito que foi observada neste canavial, mas que precisa ser analisada em outras cultivares, idade da planta, classe de solo e diferentes manejos.

CONCLUSÃO

Para os talhões deste estudo, as maiores ocorrências de comprimentos de falhas foram de 0,58 a 1,00 m no intervalo de produtividade não alcançada de 75,00 a 100,00 Mg ha^{-1}. A produção de cana não obtida decorrente das falhas pode variar para o mesmo comprimento de falha, sendo dependente do potencial produtivo no local. Devido a isso, nem sempre o talhão mais falhado é o de maior estimativa de produção não obtida devido às falhas, indicando que a tomada de decisão para a gestão canavieira baseada apenas na porcentagem de falhas é limitada. O custo econômico da falha é diretamente impactado pelo seu comprimento, independentes de sua localização no talhão. Enquanto o custo de oportunidade da falha não apenas varia conforme o seu comprimento, mas também de acordo com o potencial produtivo da região em que se encontra.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. À Solinftec pelo suporte na obtenção dos dados.

REFERÊNCIAS

AMORIM, F. R.; PATINO, M. T. O.; SANTOS, D. F. L. Soil tillage and sugarcane planting: an assessment of cost and economic viability. **Scientia Agricola**, v. 79, n. 1, 2022.

ASSOCIAÇÃO RURAL DOS FORNECEDORES E PLANTADORES DE CANA DO VALE DO PARANAPANEMA - ASSOCANA. **Custos.** 2023. Disponível em: <https://www.assocana.com.br/custos.php>. Acesso em Dez 2023.

BARBOSA JÚNIOR, M. R.; TEDESCO, D.; CORRÊA, R. G.; MOREIRA B. R. A.; SILVA, R, P.; ZERBATO, C. Mapping Gaps in Sugarcane by UAV RGB Imagery: The Lower and Earlier the Flight, the More Accurate. **Agronomy**, v. 11, n. 12, 2021.

CASAGRANDE, A. A. **Tópicos de morfologia e fisiologia da cana-de-açúcar**. Jaboticabal: FUNEP, 1991. 157p.

CAVALCANTI, R. Q.; ROLIM, M. M.; LIMA, R. P.; ORTIZ, P. F. S.; PEDROSA, E. M. R.; RODRIGUES, J.A. M. Sugarcane Row Gaps Assessment over Successive Burned and Unburned Annual Harvests. **Agronomy**, v. 13, 2545, 2023.

COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB. **Boletim da safra de cana-de-açúcar**. 2022. Disponível em: <https://www.conab.gov.br/info-agro/safras/cana/boletim-da-safra-de-cana-de-acucar>. Acesso em Fev 2024.

CONSELHO DOS PRODUTORES DE CANA DE AÇÚCAR, AÇÚCAR E ETANOL DO ESTADO DE SÃO PAULO - CONSECANA. **Custo operacional da lavoura de cana-de-açúcar**. 2023. Disponível em: <https://www.udop.com.br/u_cana/tabela_consecana_saopaulo.pdf>. Acesso em Dez 2023.

HIRSCHFELD, Henrique. **Engenharia Econômica e Análise de Custos**. 6ª ed. São Paulo: Atlas, 1998.

GOMES, J.; BAJAY, M. M. Economicidade da idade de reforma de canaviais. **Revista IPecege**, v. 3, n. 3, p. 9-22, 2017.

KLUYVER, T.; RAGAN-KELLEY, B.; PÉREZ, F.; GRANGER, B.; BUSSONNIER, M.; FREDERIC, J. et al. Jupyter Notebooks - a publishing format for reproducible computational workflows. *In*: LOIZIDES, F.; SCHMIDT, B. (Eds.). **Positioning and Power in Academic Publishing**: Players, Agents and Agendas. Amsterdã: IOS Press, 2016. p. 87-90.

LUNA, I.; LOBO, A. Mapping Crop Planting Quality in Sugarcane from UAV Imagery: A Pilot Study in Nicaragua. **Remote Sensing**, v. 8, n. 6, p. 500, 2016.

MALDANER, L. F.; MOLIN, J. P.; SILVA, E. R. O. Spatial-Temporal Analysis to Investigate the Influence of in-Row Plant Spacing on the Sugarcane Yield. Sugar Tech, v. 26, p. 194-206, 2024.

MALDANER, L. F.; CANATA, T. F.; MOLIN, J. P. An Approach to Sugarcane Yield Estimation Using Sensors in the Harvester and ZigBee Technology. **Sugar Tech**, v. 24, p. 813-821, 2022.

MALDANER, L. F.; MOLIN, J. P.; MARTELLO, M.; TAVARES, T. R.; DIAS, F. L. F. Identification and measurement of gaps within sugarcane rows for site-specific management: Comparing different sensor-based approaches. **Biosystems Engineering**, v. 209, p. 64-73, 2021.

MOLIN, J. P.; VEIGA, J. P. S. Spatial variability of sugarcane row gaps: measurement and mapping. **Ciência e Agrotecnologia**, v. 40, n. 3, p. 347-355, 2016.

OLIVEIRA, M. P.; CARDOSO, P. H.; OLIVEIRA, R. P.; BARBOSA JÚNIOR, M. R.; SILVA, R. P. Mapping Gaps in Sugarcane Fields Using UAV-RTK Platform. **Agriculture**, v. 13, 1241, 2023.

PENEDO, R.; SPEKKEN, M.; MOLIN, J. P. Um método para quantificar danos de brotação em canavial por curvatura de orientação e de paralelismo dos sulcos. *In*: CONGRESSO BRASILEIRO DE AGRICULTURA DE PRECISÃO - CONBAP, 2018, Curitiba, Paraná. **Anais** [...]. Curitiba: AsBraAp, 2018.

ROCHA, B. M; FONSECA, A. U.; PEDRINI, H.; SOARES, F. Automatic detection and evaluation of sugarcane planting rows in aerial images. Information Processing in Agriculture, v. 10, n. 3, p. 400-415, 2023,

SANTOS, H. G. et al. **Sistema Brasileiro de Classificação de Solos**. 5. ed. Brasília, DF: Embrapa, 2018. 356p.

SANTOS, F.; BORÉM, A.; CALDAS, C. **Sugarcane**: agricultural production, bioenergy and ethanol. Massachusetts: Academic Press, 2015. 830p.

SOUZA, C. H. W.; LAMPARELLI, R. A. C.; ROCHA, J. V.; MAGALHÃES, P. S. G. Mapping skips in sugarcane fields using object-based analysis of unmanned aerial vehicle (UAV) images. **Computers and Electronics in Agriculture**, v. 143, p. 49-56, 2017.

STOLF, R., IAIA, A.M., LEE, T.S.G. Índice de falhas segundo o método de STOLF: correlação com o rendimento agrícola em soqueiras de cana-de-açúcar. **Álcool e Açúcar**, v. 11, n. 58, p. 12-16, 1991.

STOLF, R. Metodologia de avaliação de falhas nas linhas de cana-de-açúcar. **STAB**, v. 4, n. 6, p.12-20, 1986.

ZENG, Z.; CUI, L.; QIAN, M.; ZHANG, Z.; KAIMIN WEI, K. A survey on sliding window sketch for network measurement. **Computer Networks**, v. 226, 109696, 2023.

4. Eletrônica e transformação digital

USO DE EQUIPAMENTOS DE BAIXO CUSTO NO DESENVOLVIMENTO DE FERRAMENTAS PARA AGRICULTURA DIGITAL

JOÃO MARCELO DOS SANTOS SOARES [1]; JOEL CARNEIRO DA CUNHA JUNIOR [1]; SIMAS SOUZA SANTANA [1]; AMÉLIA LAÍSY DO NASCIMENTO [2]; EMANOEL DI TARSO DOS SANTOS SOUSA [2]

[1]Estudante. Rua Dom Manuel de Medeiros, s/n, Dois Irmãos - CEP: 52171-900 - Recife/PE. Universidade Federal Rural de Pernambuco; [2]Professor. Rua Dom Manuel de Medeiros, s/n, Dois Irmãos - CEP: 52171-900 - Recife/PE. Universidade Federal Rural de Pernambuco

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

O uso de ferramentas de tecnologias de informação e comunicação, internet das coisas, agricultura de precisão, big data etc. na agricultura moderna tem se tornado frequente. O uso dessas tecnologias em pequenas e médias propriedades rurais podem tornar a agricultura mais competitiva, inclusiva e com maior agregação de valor. Sendo assim, o este trabalho teve como objetivo avaliar o desempenho de plataformas "open-source" no desenvolvimento de um sistema de baixo custo aplicado na aquisição, armazenamento e transmissão de dados. Foram utilizados um arduíno uno, um sensor de temperatura e umidade do ar, um módulo de posicionamento global por satélites, um módulo de comunicação por dados móveis, e leitor de cartão de memória, para tais funções. Com os dados coletados foram avaliadas a acurácia dos dados do sensor, falha no armazenamento e perda de dados na transmissão em função do intervalo de tempo de envio. Os resultados mostraram desempenho razoável dos equipamentos, com erros de leituras do sensor próximos ao anunciado pelo fabricante e falhas em média de 4,3% no envio de dados. Esses resultados indicam que tais dispositivos têm potencial para contribuir nas aplicações nas operações no campo.

PALAVRAS-CHAVE: eletrônica embarcada; sistema de baixo custo; inclusão tecnológica

ABSTRACT

The use of information and communication technology tools, internet of things, precision agriculture, big data, etc. in modern agriculture it has become frequent. The use of these technologies on small and medium-sized rural properties can make agriculture more competitive, inclusive and with greater value addition. Therefore, this work aimed to evaluate the performance of "open-source" platforms in the development of a low-cost system applied to data acquisition, storage and transmission. An Arduino Uno, an air temperature and humidity sensor, a global satellite positioning module, a mobile data communication module, and a memory card reader were used for such functions. With the collected data, the accuracy of sensor data, storage failure and data loss in transmission were evaluated depending on the sending time interval. The results showed reasonable performance of the equipment, with sensor reading errors close to those announced by the manufacturer and failures on average of 4.3% when sending data. These results indicate that such devices have the potential to contribute to applications in field operations.

KEYWORDS: embedded eletronics; low-cost system; technological inclusion

INTRODUÇÃO

É crescente a adoção de tecnologias que venham a colaborar com a identificação e análise de dados importantes para a geração de relatórios decisivos para o gerenciamento e tomada de decisões por parte dos agricultores, cada vez mais profissionalizados (PIVOTO et al., 2019). Neste sentido, a adoção das técnicas de agricultura de precisão vem, há alguns anos, sendo primordial no processo de

otimização de várias operações agrícolas, com forte atuação na intervenção baseada na variabilidade espaço-temporal das variáveis do campo (INAMASU et al., 2011). Mesmo assim, o aumento da produtividade de maneira sustentável ainda é necessário e isso fez com que nos últimos anos crescesse o uso de tecnologias de monitoramento de todos as operações inerentes ao processo produtivo agrícola (MASSRUHÁ; LEITE, 2016). Isto é possível graças à tecnologia embarcada nas máquinas atuais, que contam com sensores capazes de mensurar inúmeras variáveis (SOUZA et al., 2020). Entretanto, essas tecnologias estão disponíveis apenas em máquinas mais novas e tem o seu custo de aquisição que se encaixam melhor em grandes áreas (BASSO; ANTLE, 2020). Com a difusão dos componentes eletrônicos e dos programas de computador e linguagem de programação de código aberto, diversos pesquisadores vêm trabalhando no desenvolvimento de tecnologias com custo acessível, tendo como público-alvo os agricultores de pequena escala (FISHER e GOLD, 2012). Sendo assim, é preciso desenvolver equipamentos alternativos para auxiliar na aquisição e gerenciamento de dados visando dar suporte na compreensão dos processos e facilitar a adoção de ações preventivas, adaptativas e corretivas.

OBJETIVOS

Desenvolver equipamentos de baixo custo para aquisição de dados digitais na agricultura.

MATERIAL E MÉTODOS

O projeto foi realizado por meio do auxilio de um sistema embarcado de rastreamento que conta com um módulo receptor de sinal de sistema de posicionamento global por satélites (GPS), modelo NEO-6M-0-001 com antena externa, um módulo de comunicação por Serviços Gerais de Pacote por Rádio (General Packet Radio Service - GPRS) em conjunto com antena para amplificação de sinal para transmissão de dados, modelo SIM800L. O sistema contou também com um módulo de armazenamento em cartão de memória microSD e um sensor DHT22 para leitura de temperatura e umidade. Os módulos e sensor foram conectados a um Arduíno UNO R3 (Figura 1), responsável por controlar o funcionamento do sistema. Sua programação foi desenvolvida no programa de computador Arduino IDE.

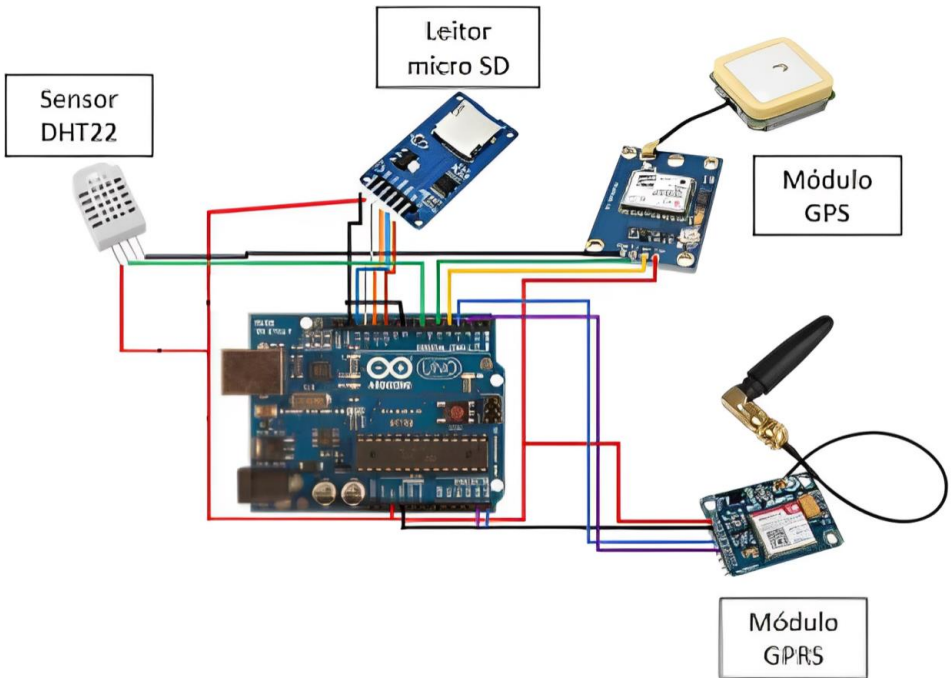


FIGURA 1. Esquema de conexões entre o Arduíno Uno, módulos e sensor.

Para a leitura dos dados de temperatura e umidade pelo sensor, foi utilizada a biblioteca <DHT.h> e como forma de avaliar a precisão do sensor, os testes foram realizados a partir da média de 10 leituras em diferentes horários e comparados com dados fornecidos pela agência "Clima Tempo". Já para o módulo GPS, como recebe os dados de posição no padrão NMEA (National Marine Eletronics Association) 0183 de navegação global, foi necessário o uso das bibliotecas <SoftwareSerial.h> e <TinyGPS.h> para facilitar a extração dos dados de latitude, longitude, altitude, data, hora, além de velocidade de deslocamento na superfície e outras informações que o módulo fornece. O módulo GPRS foi programado utilizando os comandos fornecidos pelo fabricante. Para avaliar o desempenho do módulo GPRS no envio dos dados, foram adotados os serviços de duas operadoras de telefonia móvel e os seguintes intervalos de tempo para transmissão: 10, 20, 40 e 60 segundos. Os dados transmitidos foram recebidos em um banco de dados configurado em linguagem SQL e hospedado em serviço de armazenamento em nuvem. Após o envio para o servidor web os dados foram armazenados no módulo microSD.

RESULTADOS E DISCUSSÃO

O custo com aquisição dos componentes para o desenvolvimento do sistema foi de R$ 271,00, o que permite caracterizar o projeto como sendo de baixo custo. Esse baixo custo foi possível devido à escolha de componentes de projeto aberto, que têm custo menor comparado a componentes de tecnologia proprietária com função similar (FISHER e GOLD, 2012). Os dados obtidos com o sensor DHT22 me média, se apresentaram próximos aos de fontes meteorológicas locais. As leituras apresentaram erros que foram em média 0,5ºC para temperatura e 1,5% para a umidade do ar quando comparados com os dados da Agência Clima Tempo. Sendo assim, o sensor se apresentou de forma eficiente uma vez que não apresentou influência significativa durante a coleta dinâmica de dados. Os dados obtidos a partir do sensor DHT22 e módulo GPS e que foram enviados por meio do SIM800L foram recebidos com sucesso no banco de dados criado e configurado para esse fim (Figura 2).



FIGURA 2. Interface de visualização e consulta do banco de dados em SQL hospedado na nuvem.

Para o local e momentos dos testes com o módulo SIM800L ambas operadoras apresentaram aproximadamente 4% de perdas de pacote de dados enviados. Na Tabela 1 é possível observar que as operadoras 1 e 2 apresentaram maior perda no número de pacotes de dados quando os intervalos de envio foram iguais ou inferiores a 20 segundos. As menores perdas de dados ocorreram durante a utilização da operadora 1 nos intervalos de 40 e 60 segundos, com porcentagens de 0,80 e 1,20% respectivamente.

TABELA 1. Perda na transmissão de dados ao utilizar duas operadoras sob diferentes intervalos de envio.

Dados perdidos (Operadora 1)					Dados perdidos (Operadora 2)			
10s	20s	40s	60s		10s	20s	40s	60s
27	4	2	3		16	11	9	10
11,02%	2,44%	0,80%	1,20%		6,40%	5,12%	3,60%	3,55%
Total (Operadora 1)					**Total (Operadora 2)**			
Enviados			907		Enviados			997
Perdidos			36		Perdidos			46
Proporção de perdas			3,97%		Proporção de perdas			4,61%

CONCLUSÃO

O sistema desenvolvido utilizando os componentes apontados no projeto teve custo de R$ 271,00, o que pode caracterizá-lo como sendo de baixo custo. O sensor de temperatura e umidade apresentou leituras dentro do esperado, conforme informações dadas pelo fabricante. Os módulos GPS e GPRS apresentaram bom desempenho nas condições em que foram testados. Com isso, as práticas adotadas e os equipamentos utilizados mostraram potencial e reafirma a necessidade de ampliar o seu uso nas diversas atividades agrícolas.

AGRADECIMENTOS

Agradecemos à FACEPE pela concessão da bolsa de iniciação científica.

REFERÊNCIAS

BASSO, B.; ANTLE, J. Digital agriculture to design sustainable agricultural systems. Nature Sustainability, v. 3, n. 4, p. 254-256, 2020.

FISHER, D.K.; GOLD, P.J. Open-Source Hardware Is a Low-Cost Alternative for Scientific Instrumentation and Research. Modern Instrumentation, v.1, n.2, p.8-20, 2012.

INAMASU, R. Y.; BERNARDI, A. C. C.; VAZ, C. M. P.; NAIME, J. M.; QUEIROS, L. R.; RESENDE, A. V.; VILELA, M. F.; JORGE, L. A. C.; BASSOI, L. H.; PEREZ, N. B.; FRAGALLE, E. P. Agricultura de precisão para a sustentabilidade de sistemas produtivos do agronegócio brasileiro. In: INAMASU, R. Y.; NAIME, J. M.; RESENDE, A. V.; BASSOI, L. H.; BERNARDI, A. C. C. (Ed.). Agricultura de precisão: um novo olhar. São Carlos: Embrapa Instrumentação, 2011. p. 14-26.

MASSRUHÁ, S. M. F. S.; LEITE, M. A. de A. Agricultura Digital. RECoDAF - Revista Eletrônica Competências Digitais para Agricultura Familiar, Tupã, v. 2, n. 1, p. 72-88, jan./jun. 2016. ISSN: 2448-0452.

PIVOTO, D. Scientific development of smart farming technologies and their application in Brazil. Information Processing in Agriculture, 2017.

SOUZA, K. X. S., OLIVEIRA, S. D. M., MACARIO, C. D. N., ESQUERDO, J. C. D. M., MOURA, M. F., LEITE, M. D. A., ...SANTOS, E. H.. Agricultura digital: definições e tecnologias. Embrapa Informática Agropecuária-Capítulo em livro científico (ALICE), 2020.

ZHENG, Y. AND G. DENG (1998). Benefits analysis and comprehensive evaluation of rice-fish-duck symbiotic model, Chin. J. Eco-Agric., 6: 48-51.

GEOFERT - SOLUÇÃO DIGITAL PARA GESTÃO E CONFORMIDADE NA DESTINAÇÃO DOS DEJETOS DE SUÍNOS EM SANTA CATARINA

GEORDANO DALMÉDICO [1]; CLAUDIO ROCHA DE MIRANDA [2]
[1]Analista. Concórdia, SC. Embrapa Suínos e Aves; [2]Pesquisador. Concórdia, SC. Embrapa Suínos e Aves

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
O manejo dos dejetos suínos, caso não aconteça corretamente, pode provocar poluição do solo, da água e do ar. Essa situação é mais preocupante em regiões onde a produção está mais concentrada e os resíduos orgânicos são destinados como fertilizantes das áreas agrícolas. O transporte e a destinação desses resíduos acontecem, em grande parte, sob a responsabilidade dos governos municipais. Todavia, os mecanismos de registro e acompanhamento dessa prática não permitem a adequada comprovação da sua conformidade com o que estabelece a legislação ambiental. Por isso, a Embrapa desenvolveu o GeoFert, uma solução digital que gera evidências que possibilitam comprovar se a destinação dos resíduos orgânicos aconteceu de maneira ambientalmente correta. O sistema foi testado, com sucesso, no município de Presidente Castello Branco - SC, onde também foi útil na gestão de outros serviços realizados pela frota de máquinas agrícolas do município.

PALAVRAS-CHAVE: Sistema de informação geográfica; dejetos suínos; meio ambiente

ABSTRACT
The management of swine waste can cause soil, water, and air pollution if not done correctly. This situation is particularly concerning in regions where production is more concentrated, and organic waste is used as fertilizer for agricultural areas. The transportation and disposal of this waste are largely under the responsibility of municipal governments. However, the registration and monitoring mechanisms for this practice do not allow for adequate proof of compliance with environmental legislation. Therefore, Embrapa developed GeoFert, a digital solution that generates evidence to verify whether the disposal of organic waste was conducted in an environmentally correct manner. The system was successfully tested in the municipality of Presidente Castello Branco - SC, where it was also useful in managing other services performed by the municipality's fleet of agricultural machinery.

KEYWORDS: geographic information system; swine waste; environment

INTRODUÇÃO

O Brasil é o quarto maior produtor e exportador de carne suína no mundo. Em 2023, foram produzidas mais de 5,6 milhões de toneladas. (Embrapa Suínos e Aves, 2024). Para atingir essa marca, a cadeia produtiva suinícola adota o modelo de produção de animais em confinamento (SPACs). Este modelo pode provocar consequências negativas no meio ambiente, principalmente, para solo e água, se os dejetos provenientes da produção não forem geridos corretamente (Gebler e Palhares, 2007, Seganfredo, 2020).

Considerando que estes dejetos são ricos em nutrientes, é comum que eles sejam utilizados como fertilizantes para culturas de grãos. No entanto, essa prática deve ser feita de modo bastante criterioso para não contaminar o meio ambiente. (Gatiboni e Nicoloso, 2019).

A região do Alto Uruguai Catarinense, no oeste do estado de Santa Catarina, é uma das áreas de concentração da suinocultura no Brasil. Em 2017, abrigava mais de 7,8 milhões de animais. Estima-se que a produção de dejetos gere, apenas no âmbito da referida região, aproximadamente 3 milhões de metros cúbicos anuais, constituindo-se o seu transporte e deposição como biofertilizante um dos grandes desafios dessa cadeia produtiva (Miranda e Vilas-Boas, 2022). O controle ambiental dessa prática no Estado determina que a produção de suínos seja dimensionada, de modo que os dejetos possam ser adequadamente destinados (IMA, 2021). No entanto, produtores de suínos não possuem meios para comprovar o cumprimento das regras e os órgãos ambientais não possuem meios de fiscalizar a totalidade dos empreendimentos, aumentando os riscos ambientais decorrentes do manejo incorreto.

OBJETIVOS

O objetivo deste trabalho foi o desenvolvimento e implantação, em escala piloto, de uma solução digital para comprovação do cumprimento das normas no manejo dos dejetos provenientes da produção de suínos em Santa Catarina, por meio do registro georreferenciado da sua aplicação em áreas de lavoura.

MATERIAL E MÉTODOS

Segundo Miranda e Vilas-Boas (2022), os municípios da região do Alto Uruguai Catarinense, bem como de outras regiões do Estado, passaram a assumir a responsabilidade pelo serviço de distribuição dos dejetos provenientes da produção de suínos como política pública. A execução dessa atividade segue arranjos variados: alguns municípios possuem frotas próprias e pessoal dedicado para operá-las. Outros, terceirizam para associações de produtores e há aqueles que contratam empresas privadas. A existência de mais de um modal, em um mesmo município, também ocorre.

Por isso, a execução do projeto começou pela busca de um município para ser o adotante inicial da solução. O município de Presidente Castello Branco - SC foi selecionado pois possui território relativamente pequeno, cuja produção animal, principalmente de suínos, é expressiva e onde os serviços prestados para suinocultores são gerenciados pelo poder público municipal (Miranda *et al*. 2022).

Na sequência, buscou-se conhecer o processo de prestação dos serviços, por meio da observação das atividades desenvolvidas, de entrevistas com os atores envolvidos e da análise de documentos. A partir das informações levantadas, foi possível elaborar o projeto técnico de um Sistema de Informação Geográfico - SIG (Amaral e Figueiredo, 2021) que fosse capaz de coletar, armazenar e recuperar informações sobre a prestação de serviços de aplicação de dejetos na lavoura, incluindo as coordenadas geográficas de onde foi realizado.

A próxima etapa consistiu na construção do protótipo que utilizou as linguagens de programação PHP e Dart, bem como o SGBD (Sistema Gerenciador de Banco de Dados) PostgreSQL. O sistema foi testado, os usuários foram treinados e, finalmente, ocorreu a implantação para validação no município selecionado. Durante o período de validação, os usuários receberam suporte técnico e forneceram *feedback* sobre a ferramenta.

RESULTADOS E DISCUSSÃO

O sistema de informação desenvolvido recebeu o nome de GeoFert e é composto por dois módulos. No primeiro, de gestão, o operador pode realizar o agendamento dos serviços, cadastrar os produtores e obter os registros dos serviços realizados. O segundo módulo é responsável por apresentar os

serviços agendados para os operadores que farão sua execução, bem como coletar e transmitir as informações de posicionamento geográfico durante seu atendimento.

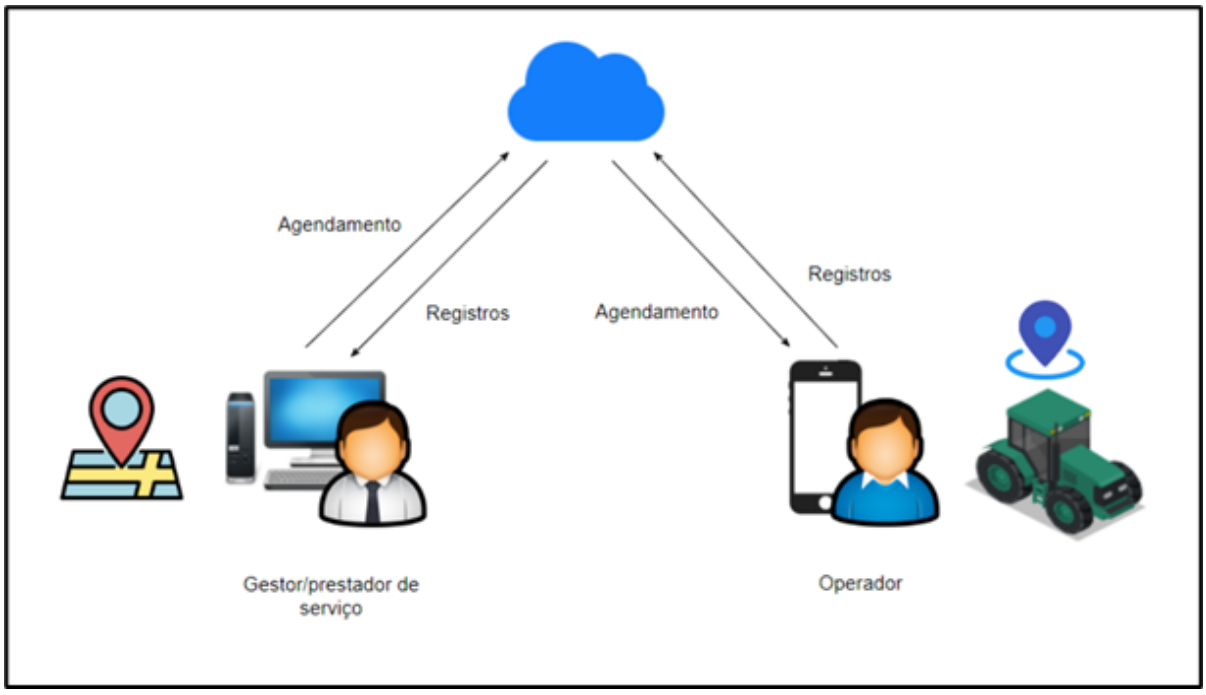


FIGURA 1. Big Picture do sistema GeoFert.

O módulo de gestão foi desenvolvido para a plataforma web e o módulo do operador consiste em um aplicativo para *smartphones* ou *tablets* Android.

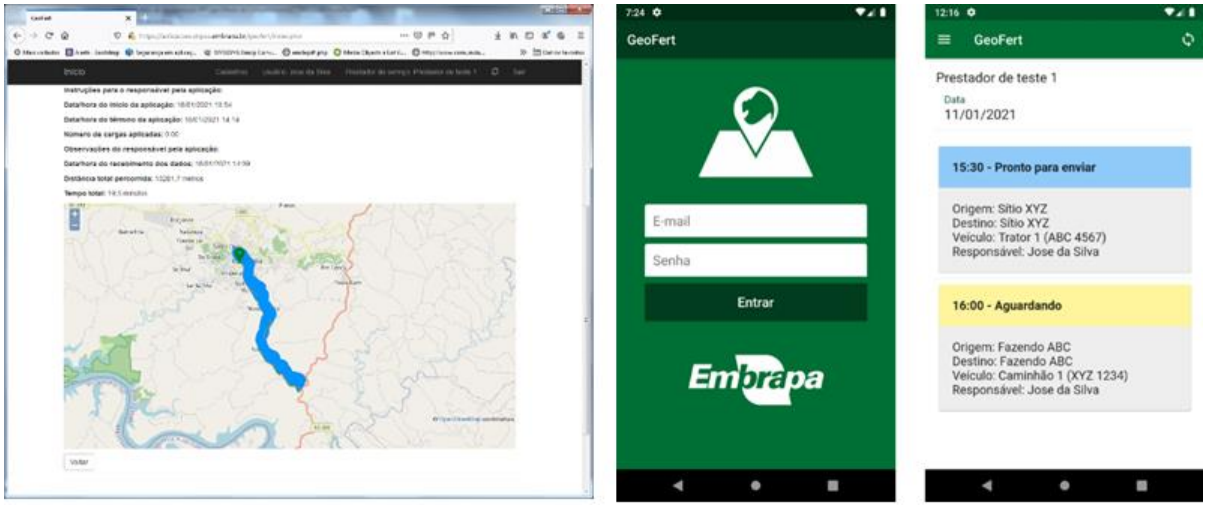


FIGURA 2. Interfaces do protótipo.

A utilização do protótipo permitiu a obtenção de registros precisos dos locais onde ocorreram as aplicações dos dejetos, bem como do tempo gasto e das distâncias percorridas. A ausência de sinal de telefonia e de internet no campo não foi um problema, visto que o aplicativo é capaz de armazenar os dados em modo off-line e transmiti-los quando uma conexão estiver disponível. Além disso, o sistema permitiu vincular os dados de localização à origem e destino do dejeto.

No entanto, percebeu-se que nem todos os operadores de maquinário agrícola foram capazes de operar o aplicativo devido ao seu nível de habilidade com o uso de *smartphones*. Para contornar essa barreira, faz-se necessário que o módulo de coleta de dados funcione de modo transparente, sem a necessidade de intervenção do operador. Uma solução possível é a utilização de sistemas de rastreamento veicular comerciais, integrados ao módulo de gestão.

Os dados gerados pelo GeoFert podem ser comparados com os dados utilizados no dimensionamento da produção, que são usados para obtenção do licenciamento ambiental. Estes dados estão disponíveis em outro sistema de informação desenvolvido pela Embrapa, o SGAS (Embrapa Suínos e Aves, 2024b). No SGAS, o produtor informa quais áreas utilizará para depositar os dejetos suínos. Por meio da comparação entre a área definida e a área efetivamente usada, cujos dados são provenientes do GeoFert, é possível verificar se o manejo está ocorrendo da forma adequada.



FIGURA 3. Cruzamento de dados permite verificar se o manejo dos dejetos está correto.

CONCLUSÃO

O GeoFert foi efetivo no registro das informações sobre a destinação dos dejetos da produção suinícola, tendo cumprido seu objetivo ao gerar evidências que possibilitam constatar se o manejo está ocorrendo de forma adequada.

Além disso, ele se mostrou, particularmente, útil para organizar o processo de prestação de diversos serviços agrícolas, não ficando restrito apenas à aplicação de dejetos na lavoura. Nesse sentido, a ferramenta pode auxiliar os municípios na gestão do maquinário e na prestação de contas sobre os recursos empregados nessas atividades.

Porém, é necessário evoluir a solução para que a coleta de dados ocorra de modo transparente aos operadores cujo nível de habilidade impede a utilização de um aplicativo. Isso pode ser feito por meio da integração com sistemas de rastreamento veicular comerciais.

Por fim, é necessário observar que o GeoFert é uma ferramenta que pode beneficiar outros atores além das prefeituras e produtores de suínos. Entre eles estão os órgãos ambientais dos Estados, cujo poder de fiscalização é limitado neste contexto. Por consequência, ao contribuir para o aumento da sustentabilidade da agropecuária nacional, a sociedade em geral também se torna beneficiária.

REFERÊNCIAS

AMARAL, L. R. do; FIGUEIREDO, G. K. D. Geoprocessamento aplicado ao gerenciamento de lavouras. In: Agricultura Digital / organização Aluizio Borém... [et al.]. - 2. Ed. - São Paulo: Oficina de Textos, 2021.

EMBRAPA SUÍNOS E AVES. Central de Inteligência de Aves e Suínos: CIAS. Concórdia, 2024. Disponível em: https://www.embrapa.br/suinos-e-aves/cias/estatisticas. Acesso em: 20 jul. 2024.

EMBRAPA SUÍNOS E AVES. SGAS - Sistema de Gestão Ambiental da Suinocultura. Concórdia, 2024b. Disponível em: https://www.embrapa.br/suinos-e-aves/busca-de-solucoes-tecnologicas/-/produto-servico/4377/sgas---sistema-de-gestao-ambiental-da-suinocultura. Acesso em: 12 Jul. 2024.

GATIBONI, L. C.; NICOLOSO, R. da S. Uso de dejetos animais como fertilizante: impactos ambientais e a experiência de Santa Catarina. Produção animal e recursos hídricos: tecnologias para

manejo de resíduos e uso eficiente dos insumos / Julio Cesar Pascale Palhares, editor técnico - Brasília, DF : Embrapa, 2019. PDF (210 p.). : il. Disponível em: https://www.embrapa.br/suinos-e-aves/busca-de-publicacoes/-/publicacao/1114228/uso-de-dejetos-animais-como-fertilizante-impactos-ambientais-e-a-experiencia-de-santa-catarina. Acesso em: 15 jul. 2024.

GEBLER, L.; PALHARES, J. C. P. (ed.). Gestão ambiental na agropecuária. Brasília, DF : Embrapa Informação Tecnológica, 2007. Disponível em: https://ainfo.cnptia.embrapa.br/digital/bitstream/item/141668/1/GEBLER-Gestao-ambiental-na-agropecuaria-2007.pdf. Acesso em: 6 ago. 2024.

IMA - Instituto do Meio Ambiente de Santa Catrina. Instrução Normativa Nº 11 - Suinoultura. 2021. Disponível em: https://in.ima.sc.gov.br/. Acesso em: 10 ago. 2024.

MIRANDA, C. R. de; VILAS-BOAS, J. Considerações sobre os programas municipais de transporte de adubo orgânico líquido de suínos: estudo de caso do Alto Uruguai Catarinense / Cláudio Rocha de Miranda e Jean Carlos Porto Vilas Boas Souza. - Concórdia : Embrapa Suínos e Aves, 2022. 28 p. Disponível em: https://www.embrapa.br/suinos-e-aves/busca-de-publicacoes/-/publicacao/1147910/consideracoes-sobre-os-programas-municipais-de-transporte-de-adubo-organico-liquido-de-suinos-estudo-de-caso-do-alto-uruguai-catarinense. Acesso em: 28 Jul. 2024.

MIRANDA, C. R. de; MONTICELLI, C. J.; SEGANFREDO, G. C.; GIACOMIN, N. J. Monitoramento de máquinas e equipamentos da frota agrícola da Secretaria de Agricultura e Meio Ambiente do município de Presidente Castello Branco, SC. / Cláudio Rocha de Miranda. - Concórdia: Embrapa Suínos e Aves, 2022. 25 p.; Disponível em: https://www.embrapa.br/suinos-e-aves/busca-de-publicacoes/-/publicacao/1149385/monitoramento-de-maquinas-e-equipamentos-da-frota-agricola-da-secretaria-de-agricultura-e-meio-ambiente-do-municipio-de-presidente-castello-branco-sc. Acesso em: 12 Jul. 2024.

SEGANFREDO, M. A.; MIRANDA, C. R. de; GUARESI, L. O balanço de nutrientes como indicador de riscos ambientais no uso de dejetos animais como fertilizante no solo. In:

MIRANDA, C. R. de; MONTICELLI, C. J.; MATTHIENSEN, A.; SEGANFREDO, M. A. (Ed.). Produção intensiva de animais e serviços ambientais: estratégias e indicadores. Concórdia: Embrapa Suínos e Aves, 2020 (Embrapa Suínos e Aves. Documentos, 211). p. 141-162

DESEMPENHO DO PACOTE DE PLANEJAMENTO DE TRAJETÓRIAS FIELDS2COVER EM TALHÕES IRREGULARES E IDENTIFICAÇÃO DE POSSÍVEIS MELHORIAS

Enzo Fabricio Casciello [1]; José Paulo Molin [2]

[1]Ex-membro de Graduação. Av. Pádua Dias, 11 ? C.P. 09 ? Piracicaba ? SP Depto de Eng. de Biossistemas, USP/ESALQ CEP: 13418-900. Laboratório de Agricultura de Precisão, Escola Superior de Agricultura 'Luiz de Queiroz', Universidade de São Paulo; [2]Coordenador e Professor Titular. Av. Pádua Dias, 11 ? C.P. 09 ? Piracicaba ? SP Depto de Eng. de Biossistemas, USP/ESALQ CEP: 13418-900. Laboratório de Agricultura de Precisão, Escola Superior de Agricultura 'Luiz de Queiroz', Universidade de São Paulo

Apresentado no

Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024

Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Este trabalho investiga o desempenho do Fields2Cover, uma biblioteca de código aberto voltada ao planejamento de trajetórias para cobertura (CPP) em ambientes agrícolas. Embora existam numerosas abordagens automatizadas em CPP para veículos agrícolas em superfícies planas, a literatura carece de soluções com código aberto que permitam análise e adição de novas funcionalidades. O objetivo deste trabalho foi analisar as limitações do Fields2Cover em talhões irregulares e declivosos, comuns especialmente no centro-sul do Brasil, já que a biblioteca em questão gera apenas percursos retilíneos e não apresenta funções de análise tridimensional do terreno. As simulações foram comparadas à geração de linhas de tráfego *in-situ* por consultores, demonstradas em mapas com sobreposições entre os dois padrões de trajetórias. Os resultados demonstram que o algoritmo enfrenta problemas na interpretação de linhas de perímetro em talhões recortados, e consequentemente apresenta dificuldades em gerar percursos que se adaptem a esta realidade. As divergências com trajetórias controle podem ser minimizadas interagindo com o ângulo das linhas de tráfego simuladas, porém gerando percursos que fogem dos limites do talhão. Futuras investigações focando em agregar melhorias ao Fields2Cover, especificamente na leitura de perímetros recortados que permitam o ajuste no ângulo do percurso, ou que habilitem modelagem tridimensional do terreno, podem ser caminhos para tornar esta biblioteca mais robusta, abrangente e usável.

PALAVRAS-CHAVE: Tráfego controlado; Planejamento de trajetórias; Software aberto

ABSTRACT

This study investigates the performance of Fields2Cover, an open-source library for coverage path planning (CPP) in agricultural environments. While there are numerous automated CPP approaches for agricultural vehicles on flat surfaces, open-source solutions that allow for analysis and the addition of new functionalities are lacking in the literature. The goal of this work was to analyze the limitations of Fields2Cover on uneven and sloping fields, prevalent mostly in the mid-south region of Brazil, given that the program generates straight paths only and lacks functions for three-dimensional terrain analysis. Simulations were compared to in-situ traffic line generation by consultants, demonstrated on maps with overlays between the two trajectory patterns. The results show that the algorithm struggles with interpreting perimeter lines on fragmented fields, consequently facing difficulties in generating paths that adapt to this reality. Divergences with control trajectories can be minimized by interacting with the angle of the simulated traffic lines, yet doing so generates paths that deviate from the field limits. Future investigations focusing on adding improvements to Fields2Cover, specifically in reading fragmented perimeters that allow for adjusting the path angle, or that enable three-dimensional terrain modeling, can be avenues to making this library more robust, comprehensive, and usable.

KEYWORDS: ;;

INTRODUÇÃO

Os constantes avanços em tecnificação e exigência por sustentabilidade na agricultura requerem maior controle das operações mecanizadas realizadas em campo (Blackmore, 2003). Uma das chaves para a eficácia da mecanização da agricultura é a capacidade de planejar trajetórias de cobertura, que garantam o atendimento completo das lavouras (Choset, 2001). Devido à crescente adoção de veículos semiautônomos e equipamentos de alta precisão no setor agrícola, é clara a necessidade de estabelecer estratégias eficientes de controle de tráfego para prevenir colisões, otimizar a eficiência operacional e prevenir o amassamento da cultura em área total (Pedersen, 2018). Trabalhos realizados que buscaram entender os motivos causadores de baixa eficiência operacional de veículos agrícolas em talhões irregulares, resultando em lucratividades baixas ou negativas, destacam diferentes fatores para cada cultura, como manobras de cabeceira em canaviais e áreas de sobreposição de aplicação em culturas de algodão (Spekken, 2015). Fatores como inclinação do terreno, que afetam na capacidade de manobra dos veículos, também afetam a qualidade do solo e sua susceptibilidade à erosão. Estudos seguintes (Spekken et al., 2016) buscaram unir o planejamento de rotas para veículos agrícolas em áreas de declive com as curvas de nível, visando reduzir perdas de solo por erosão por meio da otimização das linhas de tráfego. O Fields2Cover (F2C), proposto por Mier, Valente e de Bruin (2023), utiliza aspectos da decomposição por células e representa um avanço considerável no campo do planejamento de trajetória para cobertura (CPP - *coverage path planning*) para a agricultura, no sentido que é um software de arquitetura modular e de código aberto. Os programas publicados e disponíveis até então não revelavam seu código fonte, limitando sua aplicação à entidade desenvolvedora. O design modular permite a adição de novas funcionalidades à biblioteca, expandindo em cima de funções já programadas. Sua abordagem baseada na decomposição de campos agrícolas em células, seguida pela determinação de uma rota ótima para a cobertura, oferece uma solução prática e eficiente para a tarefa de planejamento de trajetórias. No entanto, este algoritmo foi projetado e testado principalmente para cenários agrícolas de terrenos planos, deixando questões não respondidas sobre a sua eficácia em terrenos declivosos. Como a biblioteca em questão foi construída no cenário holandês, testada e calibrada em terrenos locais, planos e com bordas pouco recortadas, espera-se observar divergências quando utilizada em talhões agrícolas brasileiros caracterizados por sua declividade e geometrias complexas.

OBJETIVOS

O objetivo do presente trabalho é compreender as funcionalidades, identificar limitações e sugerir melhorias à biblioteca Fields2Cover, para que sua proposta de CPP seja condizente em áreas declivosas e com talhões caracterizados por polígonos irregulares. A análise do algoritmo, tendo em vista a característica tridimensional das áreas agrícolas, será através do entendimento dos dados de saída quanto à geração de linhas de tráfego, com foco na perpendicularidade relativa ao declive. Tratando-se de uma avaliação de desempenho funcional do Fields2Cover, busca-se um entendimento inicial sobre a aplicabilidade e semelhança aos métodos utilizados em campo atualmente, gerando comparações de cunho qualitativo.

MATERIAL E MÉTODOS

Inicia-se por descompactar o repositório disponibilizado na página do GitHub dedicada ao programa, na aba 'Code' e 'Download ZIP', encontra-se a pasta 'src' (*source code*), contendo o código fonte do algoritmo. O usuário deve inserir parâmetros do veículo e o perímetro do talhão, via arquivo xml, para então dar início ao gerador de áreas de cabeceira, seguido da criação de percursos ao longo do talhão, definição da ordem e direção destes percursos e então a junção das rotas por meio das manobras de cabeceira, dando lugar à trajetória a ser seguida pelo veículo.

O programa foi desenhado e testado com o robô AgBot 5.115T2, de proporções muito distintas das máquinas e implementos utilizados no Brasil. Com raio de giro de apenas 2,1 m, se aproxima apenas a pulverizadores e distribuidores de sólidos autopropelidos com sistema de esterço também no rodado traseiro. Entretanto, o programa dispõe de um tipo de curva (Reeds-Shepp) que permite ré, se adaptando melhor a implementos acoplados ou máquinas autopropelidas. Também é possível alterar o raio de giro na customização dos parâmetros da máquina, modificando o tipo de manobra e área destinada a ela.

Para utilizar a biblioteca do F2C através do terminal, em Python, deve-se importar um arquivo .xml de estrutura idêntica ao arquivo teste utilizado na biblioteca. Este arquivo deve conter coordenadas que descrevam o perímetro do polígono do talhão que se deseja realizar a simulação de trajetórias. Outros formatos de arquivo não são suportados pelo pacote, então conversões podem ser necessárias.

Uma vez importado o arquivo .xml customizado, é necessária a inserção dos dados da máquina/implemento (Figura 1).

```
robot = f2c.Robot(2.0, 6.0);
robot.setMinRadius(2.0);
const_hl = f2c.HG_Const_gen()
no_hl = const_hl.generateHeadlands(field.field, 3.0 * robot.robot_width)
```

Figura 1. Especificações a serem inseridas (Fonte: Tutorial Fields2Cover)

A primeira linha atribui, respectivamente, os valores de largura efetiva e largura de trabalho da máquina/implemento. A segunda linha se refere ao raio mínimo de giro da máquina, e a quarta linha atribui a largura da área de cabaceira, neste caso multiplicando a largura efetiva da máquina por 3, porém com possibilidade de ser customizada a um valor fixo.

Os dados de saída após execução do F2C são pontos com coordenadas do sistema geográfico SRC EPSG:4326 (WGS 84), apresentadas em uma coluna na barra do terminal. Os dados de latitude e longitude, separados por vírgula, representam as linhas das trajetórias criadas pelo programa. Este tipo de resultado torna a visualização dos dados difícil quando se busca entender a relação das trajetórias de tráfego com o talhão trabalhado. Nota-se que não é possível interagir com o tipo de trajetória criada, apenas com os parâmetros de máquina/implemento e largura de áreas destinadas a manobras de cabeceira internas ao talhão. O modelo possui uma função que busca a melhor trajetória automaticamente, de modo a minimizar as distâncias e evitar sobreposições, impossibilitando a interação por parte do usuário na orientação dos percursos.

Para alterar e interagir com os parâmetros de planejamento de trajetórias do F2C, os autores apontam que a biblioteca é compatível com a interface gráfica ROS 1 e ROS 2 (Robot Operating System), utilizada para muitas funções no meio da robótica. Entretanto, as instruções fornecidas para realizar esta compatibilização são escassas. Há informações sobre como compilar a interface, porém não sobre como usá-la ou exportar os dados gerados de talhões do F2C. No presente trabalho, foi feita a instalação do sistema ROS 1, e então foram adquiridas todas as dependências necessárias por meio da interação por barra de comando, onde os itens remanescentes necessários são indicados na mensagem de erro do terminal. Especial atenção deve ser dada ao download de cerca de 500MB do visualizador 3D rviz, que é o sistema gráfico em si, dado o tamanho do pacote. De modo geral, as mensagens de erro não são claras sobre os itens restantes e como prosseguir com a compilação. Uma vez instalada e funcional, deve-se utilizar o comando **roslaunch fields2cover_ros view_field.launch** para realizar uma demonstração.

Obtiveram-se talhões específicos do município de Dois Irmãos do Tocantins, TO, disponíveis com dados de linhas de tráfego gerados por consultores com conhecimento local da área. Como o objetivo

da investigação é analisar o desempenho do pacote Fields2Cover em terrenos irregulares, a região do oeste tocantinense foi escolhida dado o seu relevo acidentado e talhões recortados.

O equipamento utilizado na operação de semeadura projetada por consultoria, considerada controle, é uma semeadora de 15 linhas e espaçamento de 0,45 m entre linhas, possuindo 6,75 m de largura efetiva. Como as linhas de tráfegos controle foram projetadas para permanecerem em uma mesma cota, o desnível dentro de um mesmo percurso de semeadura é considerado negligível. O percurso trafegável ininterrupto de maior extensão possui 1990 m e o de menor extensão é de 17 m. A área total dos talhões considerados é de 544 ha, sendo a cota máxima de 220 m e a mínima de 195 m.

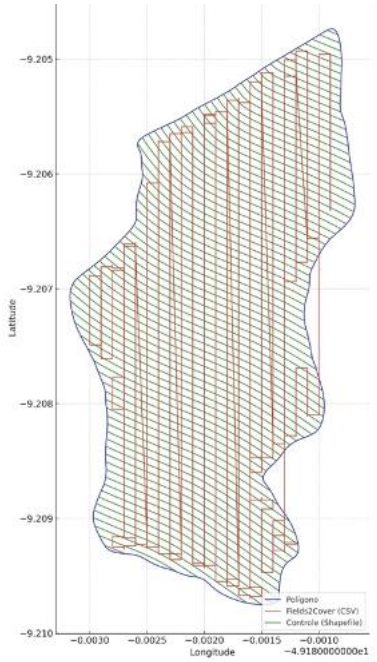
Conforme descrito anteriormente, o raio de giro do AgBot utilizado para calibrar o programa possui capacidade de manobra distinta de um conjunto trator e semeadora de arrasto, como foi o caso nos talhões analisados. Uma vez que as linhas de tráfego controle não possuem a previsão de tráfego referente às manobras de cabeceira, este comparativo não é feito. Se contrastam, através de uma análise visual empírica, os percursos internos ao talhão que tem como objetivo a cobertura da área cultivada na operação de semeadura.

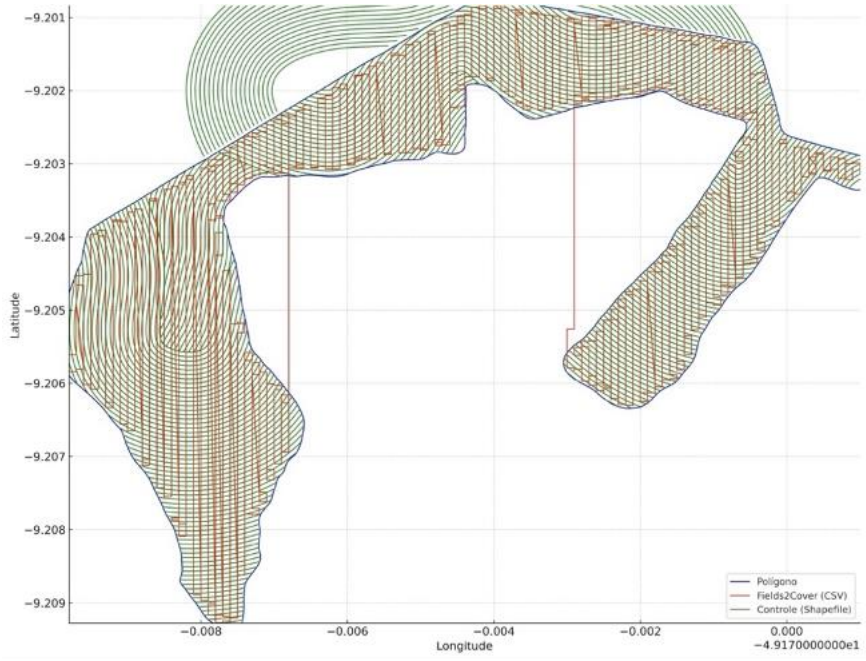
A Figura 2 traz um mapa dos talhões utilizados neste estudo para realização dos comparativos.

RESULTADOS E DISCUSSÃO

A junção de pontos das coordenadas de saída do programa, formando a trajetória de cobertura dos talhões com o Fields2Cover então sobrepostos às linhas de tráfego controle, estabelecidas previamente por meio de análise altimétrica do terreno para tráfego em nível, são apresentadas nos mapas da Figura 3, como exemplos. São destacadas as diferenças entre o controle e as linhas de tráfego obtidas a partir do Fields2Cover.

(A) (B)



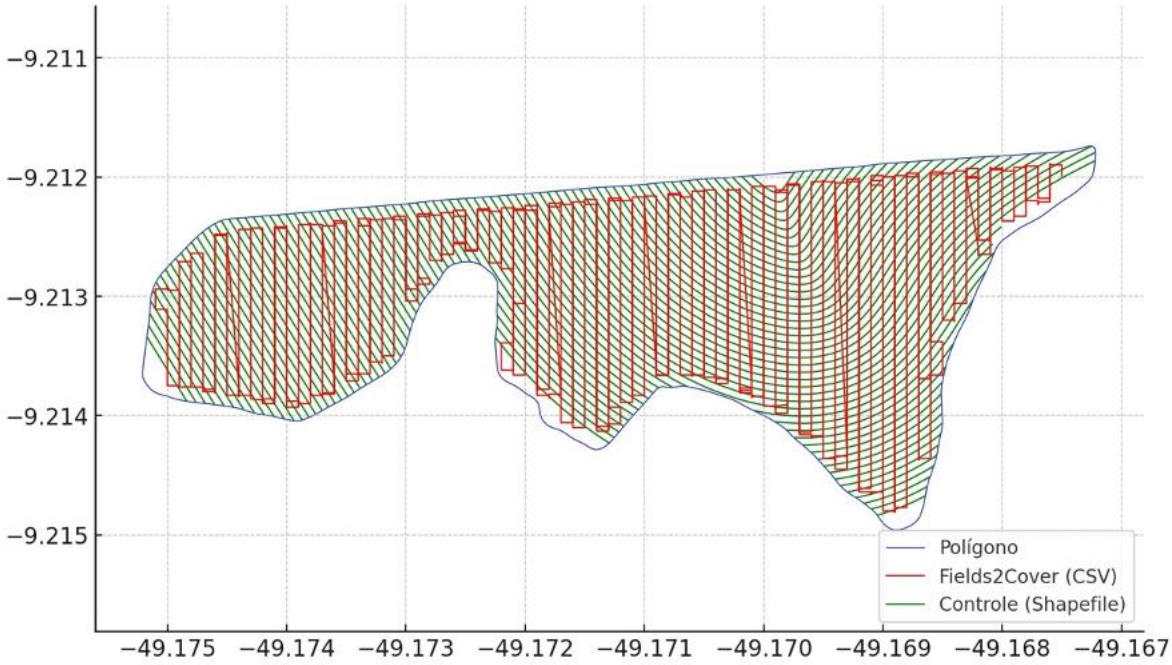


O caráter retilíneo das rotas do F2C decorre da funcionalidade do programa em buscar a menor distância entre os pontos opostos no perímetro do polígono. Isto pode garantir a minimização do deslocamento da máquina, porém não considera o propósito de se assemelhar à declividade do terreno em superfícies irregulares. Spekken et al. (2016) encontraram que em certos casos, linhas de tráfego retilíneas se assemelharam às que seguiam cotas de altitude quanto à minimização do potencial erosivo hídrico, e poderiam em alguns casos serem consideradas como opções mais viáveis, ao reduzir custos operacionais. Não obstante, isto ocorre em terrenos com pouca variação de declividade, quando as linhas de tráfego retilíneas se assemelham às linhas em nível. Para tomar proveito de tais cenários, deveria ser possível ajustar a orientação (ou ângulo de entrada no talhão) das linhas de tráfego, buscando semelhança com as cotas do terreno. A biblioteca estudada, porém, não apresenta tal funcionalidade, contando uma função responsável por buscar a orientação dos percursos automaticamente, sempre paralelos, que minimizem a quantidade de manobras de cabeceira e a somatória da distância total dos percursos. Isto resulta em uma grande limitação para sua aplicação em talhões declivosos.

Observa-se também que as manobras de cabeceira estão representadas por ângulos retos. Estas manobras não são factíveis de se realizar com veículos agrícolas e se encontram mal posicionadas, comprometendo a cobertura efetiva do talhão. Se identifica também a presença de linhas de tráfego fora dos limites do polígono do talhão, assim como quebra do paralelismo e, em alguns casos, cruzamento entre as linhas. Quando comparado ao controle, se observa uma divergência grande acerca da orientação das linhas. Nos casos abordados, as linhas de tráfego estabelecidas como controle variam de sentido conforme as cotas, raramente se assemelhando ao aspecto retilíneo.

A Figura 4 apresenta casos de percursos sugeridos pelo Fields2Cover com o ângulo de linhas de tráfego padrão do programa.

(A)



(B)

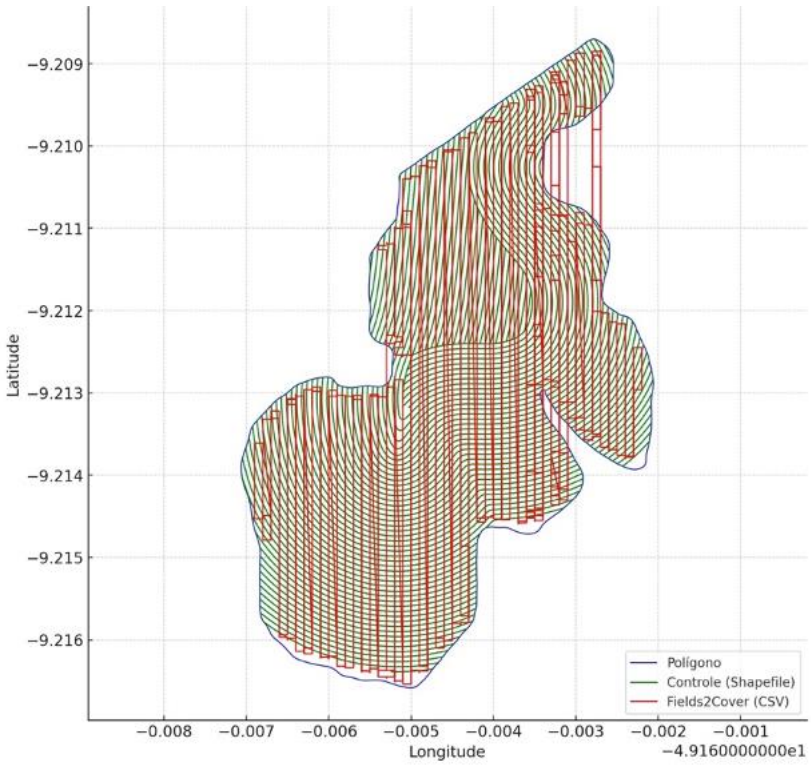


Figura 4. Mapas de talhões com sobreposições das trajetórias Controle e Fields2Cover. (A) Talhão 2, (B) Talhão 4

A Figura 5 traz o talhão da Figura 4(B) com os ângulos das linhas de tráfego modificados por meio da interface gráfica ROS, com o plugin *rqt reconfigure*.

(A) (B)



Figura 5. Talhão 4 com ângulos das linhas de tráfego customizados. (A) Evitando cruzar bordaduras côncavas, (B) Cruzando bordaduras côncavas

A modificação do ângulo das linhas de tráfego da Figura 5 teve como critério a orientação dos percursos de tráfego relativos à concavidade do polígono do talhão, de maneira a evitar o cruzamento destas bordas côncavas, como na Figura 5(A), ou não, como na Figura 5(B). Esta diferença de orientação das linhas de tráfego poderia ocorrer em função da declividade do terreno, em que se busca perpendicularidade com a declividade, e observa-se que o programa não respeita as bordaduras dos talhões quando estas são côncavas.

A presença de linhas de tráfego fora do perímetro do talhão também é evidenciada na demonstração via interface ROS na Figura 6. É possível visualizar alterações no raio de giro das manobras de cabeceira, além de ocorrerem linhas de tráfego em maior densidade, particularmente na mesma seção das linhas que fogem o perímetro do talhão. Pode-se observar como alterações nos ângulos de tráfego geram efeitos indesejados nas linhas, fazendo-as fugir do perímetro do polígono e ocorrerem em menor distância umas das outras. Na Figura 6, ambas as orientações dos percursos de tráfego sobressaem o perímetro do talhão, porém em locais distintos.

(A) (B)

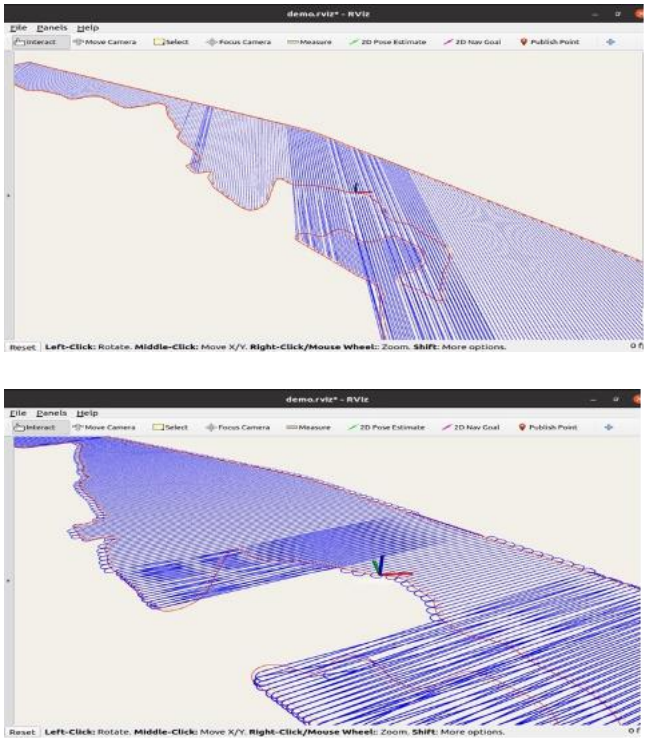


Figura 6. Talhão 18 com ângulos das linhas de tráfego customizados. (A) Transversal ao lado reto do polígono, (B) Perpendicular ao lado reto do polígono

Assim, contrastando as trajetórias de tráfego geradas pelo Fields2Cover com o projeto controle, constata-se que a maior limitação está na incapacidade de customização do ângulo das linhas de tráfego sem que o programa desrespeite o perímetro do talhão estabelecido. Utilizando como critério a maior semelhança com tráfego perpendicular à declividade, esta funcionalidade permitiria um tráfego retilíneo, sem ser totalmente em nível, porém sendo capaz de minimizar erosões de origem hídrica.

Sendo a biblioteca do Fields2Cover publicada no início de 2023, carecem análises críticas sobre sua funcionalidade em talhões declivosos que sirvam como parâmetro para comparar os resultados obtidos mediante esta investigação. O trabalho que apresenta funcionalidades de interesse a serem incorporadas no Fields2Cover é o de Spekken et al. (2016), criando algoritmos que leem o perfil tridimensional do terreno e hibridizam as cotas em linhas trafegáveis para máquinas agrícolas.

A contribuição de Nilsson e Zhou (2020) se assemelhou à abordagem do Fields2Cover, sendo relatada pelos autores como funcional em talhões de geometria complexa. Recortes nos talhões representaram dificuldades para o F2C, como observado nas figuras ilustrando a mudança de ângulo de tráfego na interface ROS. Portanto, estratégias utilizadas por estes autores poderiam contribuir com o programa este analisado com respeito ao planejamento de trajetórias em talhões recortados, especificamente as funcionalidades que impedem as linhas de tráfego de fugirem do perímetro do talhão.

CONCLUSÃO

O Fields2Cover é uma biblioteca de código aberto destinada ao planejamento de trajetórias de veículos agrícolas, especialmente útil em terrenos regulares e planos. Enfrenta limitações na geração de trajetórias curvas e reconhecimento de concavidades no perímetro de talhões. Há oportunidades para aprimorar o Fields2Cover, como melhorar sua interpretação de bordaduras irregulares, permitir ajustes nos ângulos das trajetórias em relação à declividade ou incorporar modelagem tridimensional do terreno. Tais funcionalidades poderiam permitir acesso mais amplo e aberto ao planejamento de tráfego controlado na agricultura, promovendo benefícios agronômicos, logísticos e econômicos.

REFERÊNCIAS

BLACKMORE, S. Robotic agriculture - the future of agricultural mechanisation? In: 5TH EUROPEAN CONFERENCE ON PRECISION AGRICULTURE, 2005.

CHOSET H. Coverage for robotics - A survey of recent results. **Annals of Mathematics and Artificial Intelligence**, v. 3, n.1-4, p.113-126, 2001.

MIER, G; VALENTE, J; DE BRUIN, S. Fields2Cover: An open-source coverage path planning library for unmanned agricultural vehicles. **IEEE Robotics and Automation Letters**, v. 8, n. 4, 2023.

NILSSON, R. S.; ZHOU, K. Method and benchmarking framework for coverage path planning in arable farming. **Biosystems Engineering**, v. 198, p. 248-265, 2020.

SPEKKEN, M., DE BRUIN, S., MOLIN, J. P., & SPAROVEK, G. Planning machine paths and row crop patterns on steep surfaces to minimize soil erosion. **Computers and Electronics in Agriculture**, v. 124, p. 194-210, 2016.

SPEKKEN, M. **Creating optimized machine working patterns on agricultural fields**. 2015. Tese (Doutorado em Engenharia de Sistemas Agrícolas) - Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 2015. doi:10.11606/T.11.2015.tde-22092015-112051.

DETECÇÃO DE VIROSES NO MAMOEIRO: UMA ABORDAGEM COM AUTOENCODERS

GABRIEL ANTONIO DALAPICULA SERAFINI [3]; DIOGO NOGARA NUNES [2]; JOÃO MARCELO VIEIRA ALVES FILHO [1]; BEATRIZ CORREIA DE ALBUQUERQUE [1]; LUCAS DE PAULA CORRÊDO [4]

[1]Bolsista. Laboratório de Agricultura Digital, Depto. de Agronomia, Universidade Federal de Viçosa, UFV, Viçosa ? MG. Universidade Federal de Viçosa; [2]Mestrando. Laboratório de Agricultura Digital, Depto. de Agronomia, Universidade Federal de Viçosa, UFV, Viçosa ? MG. Universidade Federal de Viçosa; [3]Doutorando. Laboratório de Agricultura Digital, Depto. de Agronomia, Universidade Federal de Viçosa, UFV, Viçosa ? MG. Universidade Federal de Viçosa; [4]Docente. Laboratório de Agricultura Digital, Depto. de Agronomia, Universidade Federal de Viçosa, UFV, Viçosa ? MG. Universidade Federal de Viçosa

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A cultura do mamão é muito expressiva no Brasil, impulsionando a economia nacional, porém, as viroses representam um desafio significativo, exigindo estratégias complexas de controle. Atualmente, a avaliação visual para detecção de doenças é subjetiva e propensa a erros. Nesse contexto, modelos baseados em Autoencoders surgem como uma alternativa promissora, oferecendo potencial na detecção de anomalias e auxiliando nos estudos de detecção de viroses no mamoeiro. Assim, objetivou-se o teste de um modelo baseado em Autoencoder para detecção de anomalias, com o intuito de auxiliar na detecção de viroses no mamoeiro. Imagens RGB foram capturadas semanalmente, usando uma câmera de 48 megapixels Ultra HD, de plantas de mamão sadias, totalizando 180 imagens por semana, eliminando imagens cortadas, ilegíveis ou embaçadas. Para simular condições anômalas, mudas de mamão sofreram intoxicação por excesso de Boro, gerando sintomas semelhantes aos das viroses, com posteriores capturas de imagens destas mudas. A arquitetura da rede consiste em um encoder que recebe imagens de entrada, enquanto o decoder restaura a imagem original. O modelo foi treinado por 100 épocas com um batch de 512, o modelo convergiu na época 48, com loss de 0,0036 para treinamento e 0,0035 para validação. O limiar estabelecido para classificação foi de 0,003638 e os valores de Precisão, Recall, F1-score e Acurácia foram de 0,66, 0,64, 0,65 e 0,65, respectivamente.

PALAVRAS-CHAVE: Fitopatologia; Inteligência Artificial; Processamento de imagens

ABSTRACT

Papaya cultivation is highly significant in Brazil, driving the national economy, yet viral diseases pose a significant challenge, demanding complex control strategies. Currently, visual assessment for disease detection is subjective and error-prone. In this context, Autoencoder-based models emerge as a promising alternative, offering potential in anomaly detection and aiding in viral diseases detection studies in papaya plants. Thus, the aim was to test an Autoencoder-based model for anomaly detection, intending to assist in viral diseases detection in papaya plants. RGB images were captured weekly using a 48-megapixel Ultra HD camera, totaling 180 images per week of healthy papaya plants, eliminating cropped, illegible, or blurred images. To simulate anomalous conditions, papaya seedlings were intoxicated with excess Boron, generating symptoms akin to viral diseases, with subsequent captures of images of these seedlings. The network architecture comprises an encoder receiving input images, while the decoder restores the original image. The model was trained for 100 epochs with a batch size of 512, converging at epoch 48, with a training loss of 0.0036 and validation loss of 0.0035. The established limiar for classification was 0.003638, with Precision, Recall, F1-score, and Accuracy values of 0.66, 0.64, 0.65, and 0.65, respectively.

KEYWORDS: ;;

INTRODUÇÃO

A produção de mamão (*Carica papaya* L.) no Brasil em 2022 contou com uma área de 26.431ha dedicados à cultura (IBGE, 2022). Em um contexto econômico, as exportações brasileiras de mamão registraram um recorde de receita em 2023, alcançando a marca de US$ 53 milhões (SILVA; BARBIERI, 2024), o que ressalta sua contribuição para a economia nacional. Entretanto, as viroses são um desafio na produção de mamão, resultando em perdas consideráveis, destacando-se o mosaico-do-mamoeiro e a meleira (LIMA et al., 2001; OLIVEIRA et al, 2011). Os danos do mosaico resultam na erradicação de cerca de 2% das plantas afetadas e a meleira perdas de até 20% quando bem manejados, podendo atingir 100% na ausência de estratégias de manejo adequadas (VENTURA et al., 2003). Quando se trata de controle, a principal estratégia adotada são as inspeções semanais aos pomares e a eliminação (*roguing*) das plantas com sintomas de vírus (LIMA et al., 2001). Dado o sucesso do roguing como medida de controle (VENTURA; MARTINS; FERREGUETTI, 2015), tornou-se obrigatória a inspeção semanal e o roguing para o controle das viroses nas áreas produtoras de mamão destinadas à exportação no território nacional (MAPA, 2010).

Atualmente, a avaliação é realizada visualmente por avaliadores treinados, conhecidos como "mosaiqueiros", ou por fiscais dos órgãos de defesa sanitária vegetal. Essa avaliação é obrigatória e o não cumprimento da medida pode resultar em multas e erradicação compulsória das plantas contaminadas (IDAF, 2019). No entanto, essa avaliação é subjetiva, o que a torna passível de erros. Assim, dois principais problemas podem ser identificados, o diagnóstico falso-negativo em que plantas contaminadas permanecem entre as saudáveis, e o *roguing* de plantas não contaminadas (falso-positivo) causando prejuízos ao produtor.

Neste contexto, técnicas como Máquinas de Vetor de Suporte (HABIB et al., 2020) e o uso de Redes Neurais Convolucionais (BACUS; LINSANGAN, 2022; VEERABALLI et al., 2020) vêm sendo testadas com relativo sucesso para a detecção de doenças no mamoeiro. Alguns modelos podem se valer de redes pré-treinadas como forma de reduzir o tempo de treinamento (KAUR; PRASHAR; KUMAR, 2022), ficando com grande número de parâmetros e assim, demandando alto poder de processamento para sua utilização. Uma possível alternativa são os Autoencoders, uma estratégia para dados não rotulados (BENFENATI et al., 2023) onde é aprendida uma função de codificação que transforma os dados de entrada e uma função de decodificação que reconstrói os dados de entrada a partir da representação codificada (DRORI, 2022). Os Autoencoders têm demonstrado grande potencial na detecção de diversas doenças em folhas (HABARAGAMUWA; OISHI; TANAKA, 2021; MAHMOUD; GUO; WANG, 2020) e frutos (LIU et al., 2022; SI; KIM, 2023) pela sua capacidade de detecção e pelo diminuto número de parâmetros. Assim, esse estudo objetivou a avaliação de um modelo baseado em Autoencoder para detecção de anomalias, com o intuito de auxiliar na de detecção de viroses no mamoeiro.

OBJETIVOS

Avaliar um modelo baseado na técnica de Autoencoder para detecção de anomalias, com o intuito de auxiliar nos estudos de detecção de viroses no mamoeiro.

MATERIAL E MÉTODOS

As imagens coloridas (RGB) foram capturadas no viveiro da Unidade de Ensino e Pesquisa (UEP) - Pomar Campus, da Universidade Federal de Viçosa (UFV), utilizando-se da câmera de celular modelo Redmi Note 12 com 48 megapixels. A configuração utilizada foi o modo automático e Ultra HD (3840 x 2160 pixels). As coletas das imagens das plantas de mamão (*Carica papaya* L.) normais ou sadias foram realizadas semanalmente, a partir do surgimento dos cotilédones após a germinação, iniciando em 01 de setembro de 2023 até 20 de outubro de 2023, quando as plantas atingiram

aproximadamente 50 dias após a germinação. As mudas de mamão pertenciam a quatro grupos: Comum, Formosa, Aliança e Solo.

As imagens foram capturadas semanalmente, sendo escolhidas 15 plantas aleatórias de um total de 150 de cada variedade, totalizando 60 plantas escolhidas aleatoriamente por semana. A captura das imagens envolveu o enquadramento lateral das plantas com variação de distância e ângulo, resultando em 3 imagens em diferentes posições por planta e assim, totalizando um mínimo de 45 imagens por variedade/grupo e 180 imagens por semana. As imagens que se apresentaram cortadas, com ângulo predominante da copa e ilegíveis ou embaçadas foram eliminadas do banco de dados.

Para simular condições anômalas de virose, 150 dias após a germinação, cinco mudas foram submetidas à intoxicação por excesso de Boro (B), devido à semelhança da sintomatologia foliar entre a toxidez (LANDI et al., 2019) e as viroses (OLIVEIRA et al., 2011; VENTURA et al., 2003), caracterizadas por manchas cloróticas, necróticas e enrolamento das folhas. Para isso, 5g de ácido bórico (H_3BO_3) foram dissolvidos em 25 ml de água destilada e aplicados 5ml por planta, totalizando 1g por planta. Uma semana após a aplicação do nutriente, quando as plantas apresentavam sintomas evidentes de fitotoxidez, foram capturadas imagens das plantas em quatro posições diferentes, totalizando 20 imagens. Da mesma forma que nas imagens normais, as imagens que apresentaram problemas foram eliminadas.

Para ampliar o banco de dados, foi adotada a técnica de ampliação de dados (Data Augmentation) com imagens sintéticas (MAN & CHAHL, 2022). Foram selecionadas aleatoriamente 322 imagens normais de diversas idades e 20 imagens anômalas previamente "cortadas", isolando o fundo da imagem alvo (foreground). Para o fundo (background), foram capturadas 4 imagens de 3 cores diferentes de papel cartão (azul, branco e preto) sob diferentes iluminações. Os foregrounds foram sobrepostos aos backgrounds, sendo invertidos horizontalmente e modificados em tamanho e posição de forma aleatória. Além disso, o brilho de ambos os elementos foi ajustado separadamente de maneira aleatória. Esse processo resultou na geração de 9.660 imagens normais e 810 imagens anômalas, formando assim o banco de dados normal e anômalo, respectivamente. Após a criação dos bancos de dados sintéticos, as imagens foram separadas em 80% para treinamento (7728 imagens), e aproximadamente 10% para teste positiva ou não anômalo (967 imagens), 10% para validação positiva ou não anômalo (966 imagens), e todas as imagens negativas ou anômalas (810 imagens) foram utilizadas para formar a validação negativa.

A arquitetura de rede foi adaptada de Collin & de Vleeschouwer (2020) e consiste em duas partes: o encoder e o decoder. O encoder recebe imagens de entrada de tamanho 256x256 com 3 canais (RGB) e possui 6 camadas convolucionais. A primeira camada convolucional tem 64 kernels, seguida por um MaxPooling de 2x2. As camadas seguintes seguem um padrão semelhante, com 32, 16 e 8 kernels, respectivamente, acompanhadas por MaxPooling cada. O decoder possui também 6 camadas e é a parte inversa do encoder, começando com uma camada convolucional com 8 kernels, seguida por um Upsampling de 2x2. As camadas subsequentes consistem em convoluções com 8, 16, 32 e 64 kernels, seguidas por um Upsampling cada. Todas as camadas convolucionais do encoder e do decoder usam a função de ativação ReLU. A última camada do decoder é uma convolução com 3 kernels, para retornar a imagem reconstruída ao padrão original RGB e com uma função de ativação linear.

O modelo foi treinado por 100 épocas no Google Colab Pro+, sendo utilizado um batch de 512. A melhor época escolhida foi a 48, onde houve convergência e os valores de loss chegaram a 0,0036 e 0,0035 para treinamento e validação. Foram utilizadas outras 100 imagens normais e anômalas, totalizando 200 imagens para os cálculos das seguintes métricas do modelo:

? Acurácia é a razão entre previsões de imagens classificadas corretamente entre todas as previsões feitas, equação: (verdadeiros positivos + verdadeiros negativos) / total de exemplos (1)

? Precisão é a fração de previsões positivas que estão realmente corretas: verdadeiros positivos / (verdadeiros positivos + falsos positivos) (2)

? Recall é a fração de instâncias positivas que são identificadas corretamente: verdadeiros positivos / (verdadeiros positivos + falsos negativos) (3)

? F1-score é a média harmônica de precisão e recuperação, é um valor que equilibra a precisão e a recuperação: 2 * ((precisão ? recall) / (precisão + recall)) (4)

O valor de loss também foi empregado para calcular o limiar, que determinou a decisão binária entre imagens normais e anômalas. O limiar estabelecido para a classificação e, consequentemente, para a elaboração da matriz de confusão foi de 0,003638.

RESULTADOS E DISCUSSÃO

Algumas redes neurais convolucionais como a YOLOv4 e suas variantes, amplamente empregadas como redes pré-treinadas em modelos de detecção e classificação de objetos, têm tamanhos variando de 1,3 MB a 236 MB (MASKI & THONDIYATH, 2021), sendo consideravelmente maiores que a rede apresenta no presente trabalho, que obteve um tamanho de 282,52 KB. Outras redes, como ReTS e VGG16, também usadas como redes pré-treinadas em modelos de detecção e classificação, possuem uma quantidade substancialmente maior de parâmetros, indo de 153,4 à 68 milhões (SHAH et al., 2022), respectivamente, em contrapartida, a arquitetura do presente modelo apresentou um total de 72.323 parâmetros treináveis. Redes maiores tornam os modelos mais exigentes em termos de poder computacional para que possa operar efetivamente, em contraste um modelo pequeno como o baseado na técnica de Autoencoders apresentado aqui, podem operar em sistemas mais simples e menos exigentes em termos computacionais.

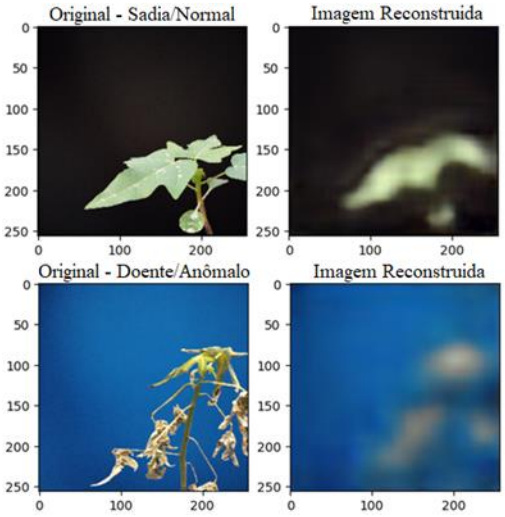


FIGURA 1. Imagens originais e reconstruídas a partir dos pesos da época 48, da esquerda para a direita na coluna e imagem normal e anômala, nas linhas de cima para baixo, respectivamente.

Apesar dos baixos valores de loss apresentados durante o treinamento e validação de 0,0036 e 0,0035 respectivamente, quando comparados a modelos de classificação supervisionados como o de Hossen et al. (2020), treinado pelo mesmo número de épocas, que obteve uma Precisão de 91% enquanto o modelo proposto enfrentou dificuldades em reconstruir com precisão as imagens originais de entrada, resultando em borrões como silhueta das imagens o que refletiu diretamente nos valores para a limiarização final do modelo e por conseguinte na precisão do modelo, embora tenha conseguido recriar o background com sucesso (Figura 1). O número limitado de imagens utilizadas para a geração do dataset sintético pode ter contribuído para um overfitting (ZENG, 2022), o que é indicado pela

rápida convergência do modelo, já na época 48 e baixo loss, mas um alto erro quando se tenta generalizar para um novo conjunto de dados.

Conforme evidenciado na matriz de confusão (Figura 2), o modelo acertou 64 imagens classificadas como sadias (verdadeiros positivos) e 67 imagens classificadas como doentes ou anômalas (verdadeiros negativos). Essas taxas de acerto são consideráveis para um modelo de natureza tão generalista quanto o proposto. No entanto, considerando a aplicação prática do modelo em campo, os prejuízos associados a erros, seja erradicando uma planta saudável ou mantendo uma planta doente no campo, seriam muito significativos para o produtor. Neste contexto, abordagens de classificação mais específicas, como o conjunto de modelos que combina três diferentes modelos de EfficientNets, conforme usado por Hridoy & Tuli (2021), demonstram um grande potencial devido à sua alta precisão na identificação das diferentes classes de doenças do mamoeiro e minimizando tanto os falsos positivos quanto os falsos negativos para todas as classes.

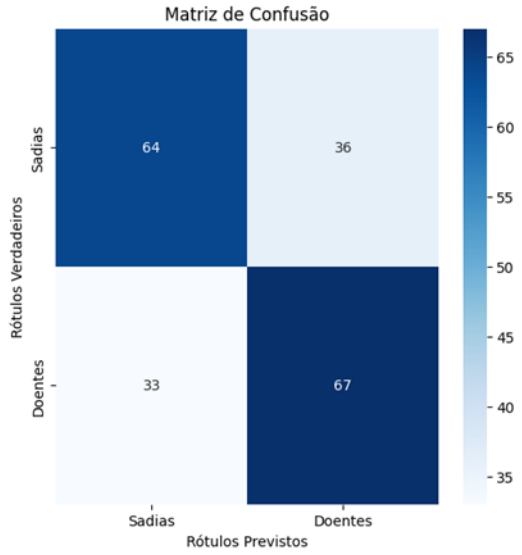


FIGURA 2. Matriz de confusão com os rótulos Verdadeiros e Previstos.

As métricas de Precisão, Recall, F1-score e Acurácia obtiveram valores de 0,66, 0,64, 0,65 e 0,65, respectivamente, indicando resultados relativamente bons. No entanto, os erros cometidos pelo modelo representam potenciais prejuízos para o produtor, ressaltando a importância de aprimoramentos na detecção de anomalias com este modelo. Outras abordagens que combinam o conceito de Autoencoders com outras técnicas têm mostrado potencial para melhorar significativamente a detecção de doenças em plantas. Um exemplo é o trabalho de Liu et al. (2022) que empregou a combinação de Autoencoder com um Classificador Auto-Supervisionado e imagens hiperespectrais para detectar anomalias em morangos. Além disso, a utilização de Autoencoders em série, como demonstrado na técnica de Autoencoder Serial Adversarial Generativo (SI & KIM, 2023), também representa uma abordagem promissora para aprimorar a detecção de doenças em plantas.

CONCLUSÃO

Embora o modelo proposto apresente resultados promissores, há desafios a serem superados para garantir sua eficácia na detecção de doenças em plantas. A utilização de abordagens combinadas, como Autoencoders em conjunto com outras técnicas, pode oferecer melhorias significativas nesse contexto.

REFERÊNCIAS

BACUS, J. A.; LINSANGAN, N. B. Detection and Identification with Analysis of Carica papaya Leaf Using Android. **Journal of Advances in Information Technology**, v. 13, n. 2, p. 162-166, 2022.

BENFENATI, A. et al. Unsupervised deep learning techniques for automatic detection of plant diseases: reducing the need of manual labelling of plant images. **Journal of Mathematics in Industry**, v.13,n.1,2023.

COLLIN, A. S.; DE VLEESCHOUWER, C. **Improved anomaly detection by training an autoencoder with skip connections on images corrupted with Stain-shaped noise**. Proceedings - International Conference on Pattern Recognition. **Anais**...2020.

DRORI, I. Variational Autoencoders. Em: **The science of deep learning**. [s.l.] Cambridge University Press, 2022. p. 22.

HABARAGAMUWA, H.; OISHI, Y.; TANAKA, K. Achieving Explainability for Plant Disease Classification with Disentangled Variational Autoencoders. 2021.

HABIB, M. T. et al. Machine vision based papaya disease recognition. **Journal of King Saud University - Computer and Information Sciences**, v. 32, n. 3, p. 300-309, mar. 2020.

HOSSEN, M. S. et al. **Deep Learning based Classification of Papaya Disease Recognition**. 2020 3rd International Conference on Intelligent Sustainable Systems (ICISS). **Anais**...IEEE, 3 dez. 2020. Disponível em: <https://ieeexplore.ieee.org/document/9316106/>

HRIDOY, R. H.; TULI, M. R. A. A Deep Ensemble Approach for Recognition of Papaya Diseases using EfficientNet Models. **2021 5th International Conference on Electrical Engineering and Information and Communication Technology, ICEEICT 2021**, n. May, p. 1-7, 2021.

IBGE, I. B. DE G. E E. **Tabela SIDRA**. Disponível em: <https://sidra.ibge.gov.br/tabela/5457>. Acesso em: 24 mar. 2024.

IDAF, I. DE D. A. E F. DO E. S. Instrução Normativa nº 002, de 24 de abril de 2019. p. 1-4, 2019.

KAUR, H.; PRASHAR, D.; KUMAR, V. Disease Identification in Papaya Plant and their Dataset. **Proceedings of 5th International Conference on Contemporary Computing and Informatics, IC3I 2022**, p. 1220-1224, 2022.

LANDI, M. et al. Boron toxicity in higher plants: an update. **Planta**, v. 250, n.4, p. 1011-1032, 24 out. 2019.

LIMA, R. C. A. et al. Etiologia e estratégias de controle de viroses do mamoeiro no Brasil. **Fitopatologia Brasileira**, v. 26, n. 4, p. 689-702, 2001.

LIU, Y. et al. Joint optimization of autoencoder and Self-Supervised Classifier: Anomaly detection of strawberries using hyperspectral imaging. **Computers and Electronics in Agriculture**, v. 198, n. 100, 2022.

MAHMOUD, M. A. B.; GUO, P.; WANG, K. Pseudoinverse learning autoencoder with DCGAN for plant diseases classification. **Multimedia Tools and Applications**, v. 79, n. 35-36, p. 26245-26263, 2020.

MAN, K.; CHAHL, J. A Review of Synthetic Image Data and Its Use in Computer Vision. **Journal of Imaging**, v. 8, n. 11, p. 310, 21 nov. 2022.

MAPA, M. DA A. P. E A. INSTRUÇÃO NORMATIVA Nº 17, DE 27 DE MAIO DE 2010. **INSTRUÇÃO NORMATIVA Nº 17, DE 27 DE MAIO DE 2010**, p. 4, 2010.

MASKI, P.; THONDIYATH, A. Plant disease detection using advanced deep learning algorithms: A case study of papaya ring spot disease. **2021 6th International Conference on Image, Vision and Computing, ICIVC 2021**, p. 49-54, 2021.

OLIVEIRA, A. A. R.; FILHO, H. P. S.; FILHO, P. E. M. Manejo de Doenças do Mamoeiro. **Embrapa Mandioca e Fruticultura - Resumo em anais de congresso (ALICE)**, n. 1, p. 8, 2011.

SHAH, D. et al. ResTS: Residual Deep interpretable architecture for plant disease detection. **Information Processing in Agriculture**, v. 9, n. 2, p. 212-223, 2022.

SI, J.; KIM, S. Chili Pepper Disease Diagnosis via Image Reconstruction Using GrabCut and Generative Adversarial Serial Autoencoder. 2023.

SILVA, B. G. L. DA; BARBIERI, M. **MAMÃO/CEPEA: Exportações de 2023 batem recorde em receita**. Disponível em: <https://www.hfbrasil.org.br/br/mamao-cepea-exportacoes-de-2023-batem-recorde-em-receita.aspx>. Acesso em: 24 mar. 2024.

VEERABALLI, R. K. et al. Deep Learning Based Approach for Classification and Detection of Papaya Leaf Diseases. Em: ABRAHAM, A. et al. (Eds.). Advances in Intelligent Systems and Computing. Cham: Springer International Publishing, 2020. v. 940p. 291-302.

VENTURA, J. A. et al. Meleira do mamoeiro: Etiologia, sintomas e epidemiologia. **Papaya Brasil**, p. 267-276, 2003.

VENTURA, J. A.; MARTINS, D. DOS S.; FERREGUETTI, G. A. Eficiência do Roguing como estratégia de manejo da meleira e mosaico do mamoeiro. **VI SIMPÓSIO DO PAPAYA BRASILEIRO**, p. 1-6, 2015.

ZENG, D. Anomaly Detection by Unsupervised Adversarial Generative Self-labelling Autoencoder. **2022 IEEE International Conference on Artificial Intelligence and Computer Applications, ICAICA 2022**, p. 1012-1021, 2022.

5. Sensoriamento e amostragem

IDENTIFICAÇÃO DE ÁREAS DE FRUTÍFERAS NA REGIÃO DO SÃO FRANCISCO PERNAMBUCANO COM USO DE SENSORIAMENTO REMOTO

Marta Laura de Souza Alexandre [1]; Elisiane Alba [2]; Henrique de Souza Gomes [3]
[1]Graduanda em Agronomia. Av. Gregório Ferraz Nogueira, s/n - Serra Talhada, PE, 56909-535. Universidade Federal Rural de Pernambuco, Unidade Acadêmica de Serra Talhada; [2]Docente . Av. Gregório Ferraz Nogueira, s/n - Serra Talhada, PE, 56909-535. Universidade Federal Rural de Pernambuco, Unidade Acadêmica de Serra Talhada; [3]Graduando em Agronomia. Av. Gregório Ferraz Nogueira, s/n - Serra Talhada, PE, 56909-535. Universidade Federal Rural de Pernambuco, Unidade Acadêmica de Serra Talhada

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
O objetivo do estudo consistiu em mapear e identificar as áreas plantadas de frutíferas na região do São Francisco Pernambucano com uso de imagens multiespectrais e inteligência artificial. Foram utilizadas imagens Sentinel-2A e OLI/Landsat 8, bem como índices de vegetação para o mapeamento automático e preciso dessas áreas. Todo o processamento das imagens e a classificação supervisionada foi conduzida na plataforma Google Earth Engine. A classificação dos pomares foi realizada utilizando o algoritmo de aprendizado de máquina SVM (*Support Vector Machine*), sendo inserido um conjunto de amostras de treinamento pertencentes a três classes: 1) Área com cultivo de uva; 2) Área com cultivo de manga; 3) Outros usos. O mapeamento para o ano de 2021 por meio do sensor MSI/Sentinel-2A demonstrou que a área plantada de espécies frutíferas na mesorregião totaliza 20.0019,58 ha no qual 7.348,62 ha correspondem a cultura da Uva e 12.670,96 ha a cultura da Manga. Os dados obtidos pelas imagens do sensor OLI/ Landsat 8 demonstraram ser semelhantes aos dados obtidos pelo sensor MSI/Sentinel-2A, no qual foi contabilizada uma área total de 19.456,85 ha, com 8.076,65 ha com a cultura da Uva e 11.380,20 ha com a cultura da Manga. Quando comparados com os dados oficiais fornecidos IBGE, o sensor Sentinel obteve um acerto de 82% enquanto o sensor Landsat de 80%. Com isso, as áreas de Uva e Manga são passiveis de serem mapeadas utilizando-se a inteligência artificial.

PALAVRAS-CHAVE: Mapeamento; Inteligência Artificial; Identificação automática

ABSTRACT
The aim of the study was to map and identify fruit-growing areas in the São Francisco region of Pernambuco using multispectral images and artificial intelligence. Sentinel-2A and OLI/Landsat 8 images, as well as vegetation indices, were used for the automatic and precise mapping of these areas. All image processing and supervised classification were conducted on the Google Earth Engine platform. Orchard classification was performed using the Support Vector Machine (SVM) machine learning algorithm, with a set of training samples belonging to three classes: 1) Grape cultivation area; 2) Mango cultivation area; 3) Other uses. Mapping for the year 2021 using the MSI/Sentinel-2A sensor showed that the planted area of fruit species in the mesoregion totals 20,019.58 ha, of which 7,348.62 ha correspond to Grape cultivation and 12,670.96 ha to Mango cultivation. The data obtained from the OLI/Landsat 8 sensor images were similar to those obtained from the MSI/Sentinel-2A sensor, with a total area of 19,456.85 ha, including 8,076.65 ha of Grape cultivation and 11,380.20 ha of Mango cultivation. When compared with official data provided by IBGE, the Sentinel sensor achieved an accuracy of 82%, while the Landsat sensor achieved 80%. Thus, Grape and Mango areas can be mapped using artificial intelligence.

KEYWORDS: Mapping; Artificial intelligence; Automatic identification

INTRODUÇÃO

O Brasil configura-se como o terceiro maior produtor de frutas no mundo, com uma produção equivalente a 43,6 milhões de toneladas, resultando em uma área plantada em torno em 2,2 milhões de hectares, sendo responsável por grande parte da mão de obra da atividade agrícola no Brasil (COELHO, SCHMILDT, ZUCOLOTO, 2015). O cultivo de frutas no Brasil está diretamente relacionado com o cenário socioeconômico do país, com a intensiva utilização da mão de obra, com o grande rendimento por área, que possibilita o desenvolvimento de agroindústrias, além da importância nutricional das frutas na complementação alimentar (FACHINELLO, NACHTIGAL, KERSTEN, 2008).

As condições ecológicas no Brasil são adequadas para produzir uma variedade de frutas de ótima qualidade, sendo frutas tropicais, subtropicais e temperadas, devido à grande diversidade de solos e climas no país. Dando ênfase ao Nordeste brasileiro com as altas temperaturas durante o ano e os modernos sistemas de irrigação que apresentam condições favoráveis para a produção de frutas (BUSTAMENTE, 2009). No estado de Pernambuco, o município de Petrolina pertencente ao Vale do Rio do São Francisco, tem grande destaque na produção de frutas, sendo a segunda maior região dos vinhos de todo o país e uma das maiores exportadoras de manga do Brasil.

No entanto a escassez de informações e dados a respeito da extensão e localidade das áreas plantadas na região é um problema, pois tais informações são primordiais para o planejamento agrícola. Com isso, diante desse cenário o uso de imagens multiespectrais aliada as técnicas de inteligência artificial, apresentam um grande potencial no monitoramento das frutíferas durante todo o seu ciclo, além da utilização de imagens de alta resolução espacial, com o uso de RPA (*Remotely Piloted Aircraft* - Aeronave Remotamente Pilotada) para obtenção do comportamento espectral das espécies frutíferas, associando também as imagens multiespectrais.

O uso de imagens multiespectrais associado as técnicas de inteligência artificial, com o uso do algoritmo *Support Vector Machine* (SVM), podem auxiliar na determinação da localidade e extensão das áreas de frutíferas plantadas. O algoritmo SVM consiste em uma técnica computacional de aprendizado para problemas de reconhecimento de padrão, esse algoritmo busca uma linha de separação entre duas classes distintas, o SVM escolhe a reta entre eles, também chamada de hiperplano em maiores dimensões. A partir dos novos dados ele agrupa qual das classificações faz mais sentido (NASCIMENTO et al, 2009).

Nesse contexto, a utilização das imagens de alta resolução espacial, associada as técnicas de inteligência artificial e as imagens multiespectrais, demonstram grande potencial para determinação da localização e extensão das áreas frutíferas, bem como a identificação automática dos padrões espectrais das espécies frutíferas da região do Vale de São Francisco pernambucano, com isso o objetivo desse estudo consistiu em mapear e identificar as áreas plantadas de frutíferas cultivadas na região do São Francisco Pernambucano com uso de imagens multiespectrais e inteligência artificial.

OBJETIVOS

2.1 Objetivo geral desse estudo consistiu em mapear e identificar as áreas plantadas de frutíferas cultivadas na região do São Francisco Pernambucano com uso de imagens multiespectrais e inteligência artificial.

2.2 Objetivos específicos

- Correlacionar diferentes imagens multiespectrais e a inteligência artificial para a distribuição espacial de áreas de frutíferas;

- Elaborar banco de dados robusto para o treinamento do algoritmo e predição automática anualmente;
- Fornecer dados úteis para a gestão do setor de frutíferas e assim, contribuir para a expansão da atividade no interior de Pernambuco.

MATERIAL E MÉTODOS

Área de Estudo

A área de estudo (Figura 1) correspondeu a mesorregião do São Francisco Pernambucano, que é formada por duas microrregiões e que abrange 15 municípios. Está localizada no centro sul do estado de Pernambuco, sendo circundada pela margem esquerda do Rio São Francisco. Devido ao rio, a região apresenta uma desenvolvida agricultura irrigada, com ênfase no município de Petrolina, representando um grande polo frutífero de importância mundial. A vegetação nativa é composta por Caatinga e os índices pluviométricos da região são muito baixos, entre 400 mm e 800 mm (IBGE, 2023).

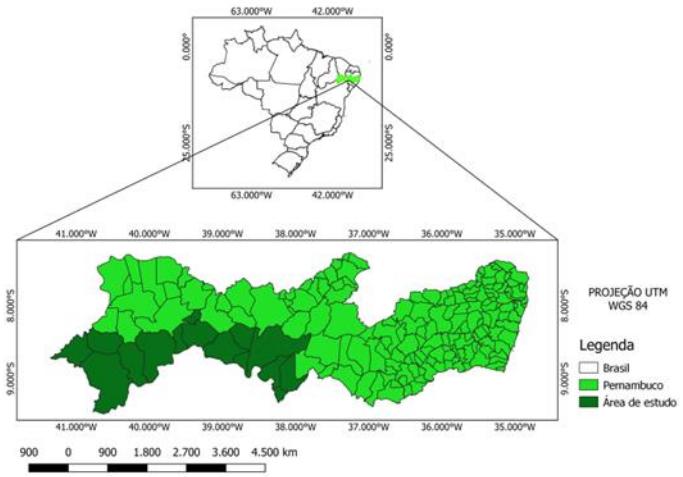


FIGURA 1. Mesorregião do São Francisco Pernambucano.

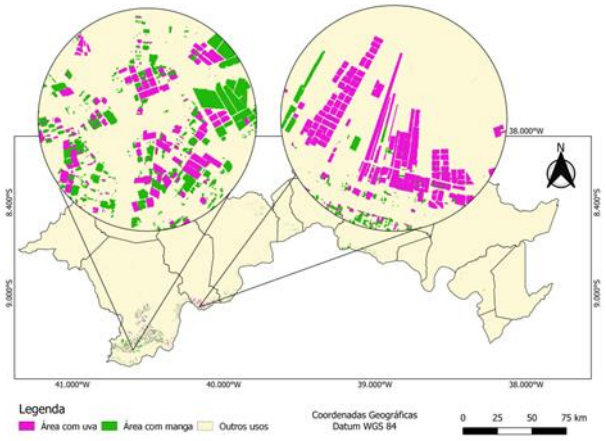
Dados espaciais

A Figura 2 apresenta os procedimentos metodológicos adotados no presente estudo, em que as imagens espaciais foram obtidas por meio dos sensores Landsat 8 e Sentinel 2A, onde o primeiro corresponde a um satélite de observação da Terra, operado pela NASA e USGS (US *Geological Survey*), o mesmo atua por meio de dois sensores principais: *Operational Land Imager* (OLI), o qual dispõe de nove bandas multiespectrais atuando na região do visível, infravermelho próximo e infravermelho médio; e o segundo sensor - *Thermal Infrared Sensor* (TIRS) que opera na faixa do termal - Luz Infravermelha de Onda Longa, o satélite possui imagens com resolução moderada variando de 15 m até 100 m (EOS, 2022). O sensor Sentinel 2A, corresponde a um satélite, operado pela Agência Espacial Europeia (ESA), constituído de dois sensores: o sensor multiespectral MSI (*Multispectral Imager*) com 13 bandas espectrais, variando de 443 a 2190 nm, com resolução espacial de 10m para as bandas do visível, 20m para o infravermelho e 60m para as bandas de correção atmosférica, o segundo sensor - *Synthetic Aperture Satellite* (SAR), que possui radares com capacidade de obter imagens tanto diurnas quanto noturnas, possui resolução espacial de 5 metros e resolução radiométrica de 10 bits (EMBRAPA, 2020).

RESULTADOS E DISCUSSÃO

Os mapeamentos das áreas com as com as culturas de uva e manga para os sensores Sentinel 2A e Landsat 8 podem ser visualizados nas Figura 3. Para o sensor Sentinel 2A a implantação de ambas as espécies frutíferas está situada predominantemente no município de Petrolina. Além disso, foi possível observar municípios que não possuem áreas plantadas com as espécies de frutíferas em estudo, como é o caso dos municípios de Afrânio, Dormentes, Cabrobó, Terra Nova, Itacuruba, Carnaubeira, Floresta, Tacaratu e Jatobá.

a)



b)

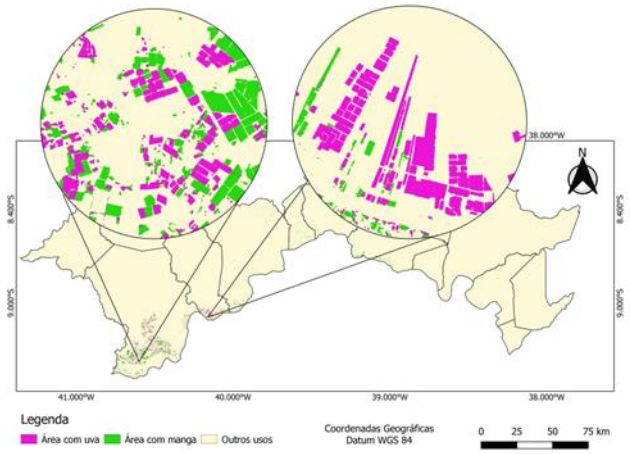


FIGURA 3. Identificação das principais frutíferas por meio do algoritmo SVM a partir de imagens Sentinel 2A (a) e Landsat 8 (b).

O município de Petrolina detém a maior área em hectares de frutíferas plantadas, correspondendo a 14.814,57 ha, dos quais 5.556,12 ha correspondem as áreas plantadas com uva e 9.258,45 ha com cultivo de manga. Em seguida está Belém do São Francisco e Santa Maria da Boa Vista com uma área plantada de manga totalizando 1.350,89 e 1.126,07 ha respetivamente. Lagoa Grande configura-se como o segundo maior município com áreas com a cultura da uva, totalizando 1.494.54 ha.

Assim como na classificação com o sensor Sentinel 2A, a classificação com o sensor Landast 8 também demonstrou que o município de Petrolina possui as maiores áreas plantadas com as frutíferas de interesse, em seguida está Lagoa Grande e Santa Maria da Boa Vista.

O mapeamento das áreas com as frutíferas com variedades de uva e manga com o sensor Landsat 8 diferentemente do sensor Sentinel 2A não identificou as áreas com a cultura da uva presentes nos municípios de Petrolândia e Orocó, por possuir bandas com uma resolução espacial de 30m, dificultando a identificação das frutíferas em áreas menores.

O mapeamento para o ano de 2021 por meio do sensor MSI/Sentinel-2A demonstrou que a área plantada de espécies frutíferas na mesorregião do São Francisco Pernambucano totaliza 20.0019,58 ha no qual 7,348,62 ha correspondem a cultura da Uva e 12,670,96 ha a cultura da Manga, dentre os municípios mais produtores estão Petrolina, Belém do São Francisco, Santa Maria da Boa Vista e Lagoa Grande. Os dados obtidos pelas imagens do sensor OLI/ Landsat 8 demonstraram-se semelhantes aos dados obtidos pelo sensor MSI/Sentinel-2A, no qual foi contabilizada uma área total de 19.456,85 ha, com 8.076,65 ha com a cultura da Uva e 11.380,20 ha com a cultura da Manga. Quando comprados com os dados oficiais fornecidos, o sensor Sentinel obteve um acerto de 82% enquanto o sensor Landsat de 80%.

Os valores de Kappa obtidos na classificação supervisionada pelo algoritmo SVM para sensor Sentinel2A e Landsat 8, para os quinze municípios, apresentaram um valor de 0,656 e 0,659, com acurácia geral de 99,41% e 99,48% respectivamente, a diferença nos valores de Kappa para ambos os sensores não é considerada significativa, em vista disso, ambos demonstram um bom desempenho na classificação.

Corroborando com esses resultados, em um estudo desenvolvido por Silva et al. (2009), o algoritmo SVM indicou um ótimo desempenho na avaliação da cobertura das Terras. Do mesmo modo, em estudo desenvolvido por Estrabis, Junior e Pistori (2019), ao mapear a Vegetação Nativa do Cerrado na Região de Três Lagoas-MS com o Google Earth Engine - GEE, o algoritmo SVM também demonstrou um ótimo desempenho na classificação.

Ambos os sensores demonstraram que são eficientes para determinação da localização e extensão das áreas frutíferas, pois de acordo com os dados base do IBGE, as áreas com as culturas da uva e manga totalizam 23.893 ha o sensor Landsat8 identificou 19.456,85 e o sensor Sentinel 2A 20.019,58 ha. A partir do conhecimento desses resultados, essa metodologia será aplicada de forma anual e contínua, disponibilizando o mapeamento das áreas abrangidas pelas diferentes espécies frutíferas no estado.

CONCLUSÃO

O mapeamento da cultura da uva foi altamente passível de ser identificada para ambos os sensores, no entanto sensor Sentinel 2A apresentou um melhor desempenho na classificação para ambas as frutíferas, pois os valores se assemelham com os dados do IBGE para o ano de 2021, demonstrando eficiência na determinação da localização e extensão das áreas frutíferas

Quanto a classificação supervisionada com o algoritmo SVM das espécies frutíferas na mesorregião do São Francisco Pernambucano, o mesmo demonstrou eficiência na classificação pois apresentou ótimos valores de Kappa e acurácia, para os quinze municípios.

REFERÊNCIAS

BUSTAMANTE, Paula Margarita Andrea Cares. A fruticultura no Brasil e no Vale do São Francisco: vantagens e desafios. Revista Econômica do Nordeste, v. 40, n. 1, p. 153-172, 2009.

COELHO, R. I.; SCHMILDT, E. R.; ZUCOLOTO, M. Fruticultura tropical: diversificação e consolidação. Livros, 2015.

EOS. EOS Data Analytics, 2022. Disponível em:<https://eos.com/pt/blog/bandas-de-landsat-8/>. Acesso em: 06 de fev. de 2023.

ESTRABIS, Nayara Vasconcelos; MARCATO JUNIOR, J.; PISTORI, Hemerson. Mapeamento da Vegetação Nativa do Cerrado na Região de Três Lagoas-MS com o Google Earth Engine. Revista Brasileira de Cartografia [Online], v. 71, p. 702-725, 2019.

EMBRAPA. SENTINEL - Missão Sentinel. 2020. Disponível em:< https://www.embrapa.br/satelites-de-monitoramento/missoes/sentinel>. Acesso em: 15 de maio de 2023.

FACHINELLO, J.C.; NACHTIGAL, J. C.; KERSTEN, E. Fruticultura: fundamentos e práticas. Embrapa Clima Temperado, 2008.

NASCIMENTO, R. F. F. et al. O algoritmo Support Vector Machines (SVM): avaliação da separação ótima de classes em imagens CCD-CBERS-2. Simpósio Brasileiro de Sensoriamento Remoto, v. 14, p. 2079-2086, 2009.

IBGE. Instituto Brasileiro de Geografia e Estatística, 2023. Cidades e Estados. Disponível:

https://cidades.ibge.gov.br/. Acesso: 20 de jan.de 2023.

QGIS DEVELOPMENT TEAM, 2023. QGIS Geographic Information System. Open-Source Geospatial Foundation Project. Disponível em: <http://www.qgis.org/>. Acesso em: 21 jan. 2023.

SILVA, E. da et al. Teste do classificador" Support Vector Machine"(SVM) para a avaliação da cobertura das terras em imagens capturadas do software Google Earth®, 2009.

MONITORAMENTO DA PALMA FORRAGEIRA COM SENSOR RGB A BORDO DE VEÍCULOS NÃO TRIPULADOS

Henrique de Souza Gomes [1]; Alan Cesar Bezerra [2]; Marta Laura de Souza Alexandre [3]
[1]Graduando em Agronomia . Av. Gregório Ferraz Nogueira, s/n - Serra Talhada, PE, 56909-535. Universidade Federal Rural de Pernambuco, Unidade Acadêmica de Serra Talhada; [2]Docente. Av. Gregório Ferraz Nogueira, s/n - Serra Talhada, PE, 56909-535. Universidade Federal Rural de Pernambuco, Unidade Acadêmica de Serra Talhada; [3]Graduanda em Agronomia. Av. Gregório Ferraz Nogueira, s/n - Serra Talhada, PE, 56909-535. Universidade Federal Rural de Pernambuco, Unidade Acadêmica de Serra Talhada

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
O uso de plantas forrageiras adaptadas é crucial na agropecuária, especialmente em regiões áridas e semiáridas. A palma forrageira se destaca nessas áreas devido ao seu alto rendimento e baixo custo. O sensoriamento remoto, agora facilitado pelos VANTs, oferece oportunidades para monitoramento contínuo e de alta resolução. Embora os sensores RGB sejam comuns, estudos explorando índices de vegetação alternativos mostram promessa. No entanto, há uma lacuna na avaliação da palma forrageira nesse contexto, o que poderia beneficiar os produtores na melhoria do manejo de suas produções. A pesquisa foi feita em uma área experimental na Universidade Federal Rural de Pernambuco, Unidade Acadêmica de Serra Talhada, localizada no município de Serra Talhada-PE.

Coletou-se as respostas dos índices de vegetação proposto em nível de pixel na planta fixa, Palma Orelha de Elefante Mexicana durante o período de avaliação a partir do qual realizou-se uma correlação com o índice de área do cladódio (IAC). Foram gerados modelos linear e quadrático a fim de testar os índices de vegetação que possuíam uma melhor resposta espectral como variável independente e o IAC como variável dependente.

Os resultados revelaram correlações significativas entre o Índice de Área do Cladódio (IAC) e cinco índices de vegetação (VARI, MGRVI, COM, NGRDI e VEG), todos com valores acima de 0,3 para a palma Orelha de Elefante (OEM). Os mapas temáticos destacaram a capacidade dos índices VARI, VEG e NGRDI em caracterizar diferentes coberturas vegetais e clones de palmas na área de estudo. No entanto, os modelos de regressão linear e quadrática não apresentaram ajustes satisfatórios para predição do IAC, sugerindo que as características morfológicas dos cladódios podem influenciar na resposta espectral da cultura. Esses resultados contrastam com estudos anteriores e destacam os desafios na estimativa do IAC em palmas forrageiras devido à complexidade morfológica dos cladódios.

O estudo investigou a resposta espectral da palma forrageira por meio de sensores RGB em VANTs. Os índices de vegetação VARI, VEG e NGRDI não apresentaram correlações satisfatórias com o Índice de Área de Cladódio (IAC), com valores abaixo de 0,5. Apesar da boa visualização da variabilidade espacial da palma, as análises de regressão linear e quadrática não mostraram ajustes significativos ($r^2 < 0,3$) entre esses índices e o IAC. Esses resultados ressaltam desafios na estimativa do IAC utilizando sensores RGB em VANTs.

PALAVRAS-CHAVE: SENSORIAMENTO; PLAMA FORRAGEIRA; SENSOR RGB

ABSTRACT
The use of adapted forage plants is crucial in agriculture, especially in arid and semi-arid regions. Forage cactus stands out in these areas due to its high yield and low cost. Remote sensing, now

facilitated by UAVs, offers opportunities for continuous, high-resolution monitoring. Although RGB sensors are common, studies exploring alternative vegetation indices show promise. However, there is a gap in the evaluation of forage cactus in this context, which could benefit producers in improving the management of their production. The use of forage plants adapted to the region's climatic conditions is an important alternative in agricultural production, especially in arid and semiarid. Forage cactus is a crop used in these regions due to its good yield of fresh biomass, high water content, good acceptability and low production cost. Remote sensing has been a tool used in agricultural monitoring, but its adoption is limited due to the demands for mapping with spatial resolutions on centimeter scales and the presence of clouds. The popularization of UAVs has once again highlighted this technology as it presents potential for applications and overcomes the difficulties presented by the sector. The research was carried out in an experimental area at the Federal Rural University of Pernambuco, Serra Talhada Academic Unit, located in the municipality of Serra Talhada-PE.

The responses to the proposed vegetation indices were collected at pixel level on the fixed plant, Palma Orelha de Elefante Mexicana, during the evaluation period, from which a correlation was made with the cladode area index (IAC). Linear and quadratic models were generated in order to test the vegetation indices that had a better spectral response as the independent variable and the IAC as the dependent variable.

The results revealed significant correlations between the Cladode Area Index (IAC) and five vegetation indices (VARI, MGRVI, COM, NGRDI and VEG), all with values ??above 0.3 for the Elephant Ear Palm (OEM). The thematic maps highlighted the ability of the VARI, VEG and NGRDI indices to characterize different vegetation covers and palm clones in the study area. However, the linear and quadratic regression models did not present satisfactory adjustments for predicting the IAC, suggesting that the morphological characteristics of the cladodes may influence the spectral response of the culture. These results contrast with previous studies and highlight the challenges in estimating IAC in forage palms due to the morphological complexity of the cladodes.

The study investigated the spectral response of cactus using RGB sensors in UAVs. The vegetation indices VARI, VEG and NGRDI did not show satisfactory correlations with the Cladode Area Index (IAC), with values ??below 0.5. Despite the good visualization of the spatial variability of the palm, the linear and quadratic regression analyzes did not show significant adjustments ($r^2 < 0.3$) between these indices and the IAC. These results highlight challenges in estimating IAC using RGB sensors in UAVs.

KEYWORDS: ;;

INTRODUÇÃO

Na produção agropecuária, o uso de plantas forrageiras adaptadas às condições climáticas da região é uma importante alternativa para manter a disponibilidade de alimentos aos animais nos períodos sazonais, em especial na estação seca do ano (Santos et al., 2017), em especial em regiões áridas e semiáridas. Entre as culturas mais utilizadas para ambientes áridos e semiáridos, a palma forrageira (Opuntia spp. e Nopalea spp.) é uma alternativa que se destaca por possuir um bom rendimento de biomassa fresca, elevado teor de água, boa aceitabilidade e baixo custo de produção (Jardim, 2019).

O uso de sensoriamento remoto para monitoramento agrícola, seja em aeronaves tripuladas ou em satélites, tem sido pesquisado desde a década de 60, contudo, as demandas por mapeamentos com resoluções espaciais em escalas centimétricas, a presença de nuvens e demora para obtenção e processamento sempre foram limitações (Pessi et al., 2020). Com isso, os produtores não conseguiam utilizar desta tecnologia para tomada de decisões rápidas e corretas, impedindo uma adoção do sensoriamento remoto no dia a dia dos sistemas de produção.

Mais recentemente, a popularização dos veículos aéreos não tripulados (VANTs) tem voltado a dar destaque à esta tecnologia por apresentar um potencial de aplicações e superando as dificuldades apresentadas pelo setor do sensoriamento remoto, como escala refinada e o monitoramento contínuo (Arantes et al., 2020). No monitoramento da cobertura vegetal, a faixa espectral de maior interesse se encontra no infravermelho próximo (NIR), no entanto, os sensores para medição desta faixa do espectro possuem elevados custos de obtenção e manutenção, o que inviabiliza o uso destes equipamentos específicos pelos produtores de pequeno e médio porte.

Dessa forma, os VANTs mais acessíveis são os que possuem sensores apenas na faixa do visível (RGB) que, por sua vez, tem estimulado pesquisas de índices alternativos de vegetação para essas frequências (Sampaio et al., 2020). Entre os estudos desenvolvidos, pode-se destacar um apresentado por Barbosa et al. (2019) que avaliaram índices de vegetação obtidos com sensor convencional RGB em VANTs em grama esmeralda (Zoysia japonica) e obtiveram bons resultados no monitoramento dessa planta. Arantes et al. (2020) conseguiram empregar esta tecnologia de monitoramento hídrico em laranjais e conseguiram detectar e mapear as plantas com diferentes níveis de estresses. No entanto, não há estudos que busquem avaliar a área foliar dessa cultura associado com sensor RGB e índices de vegetação no visível que auxiliem os produtores das regiões áridas e semiáridas a melhorar o manejo de suas produções.

OBJETIVOS

Investigar a performance de modelos de regressão com veículo aéreo não tripulado (VANT), embarcado com um sensor RGB, na estimativa de área foliar de palma forrageira em uma região de semiárido.

MATERIAL E MÉTODOS

3. Metodologia

3.1 Área de estudo

O experimento foi conduzido na Universidade Federal Rural de Pernambuco, Unidade Acadêmica de Serra Talhada, localizado no município de Serra Talhada, Pernambuco. A região é caracterizada pelo clima tipo BSw'h' - semiárido, quente e seco, com precipitação pluviométrica anual de 657 mm.ano-1 e temperatura média anual de 25,8 ºC (Alvares et al., 2013; Lins et al., 2017).

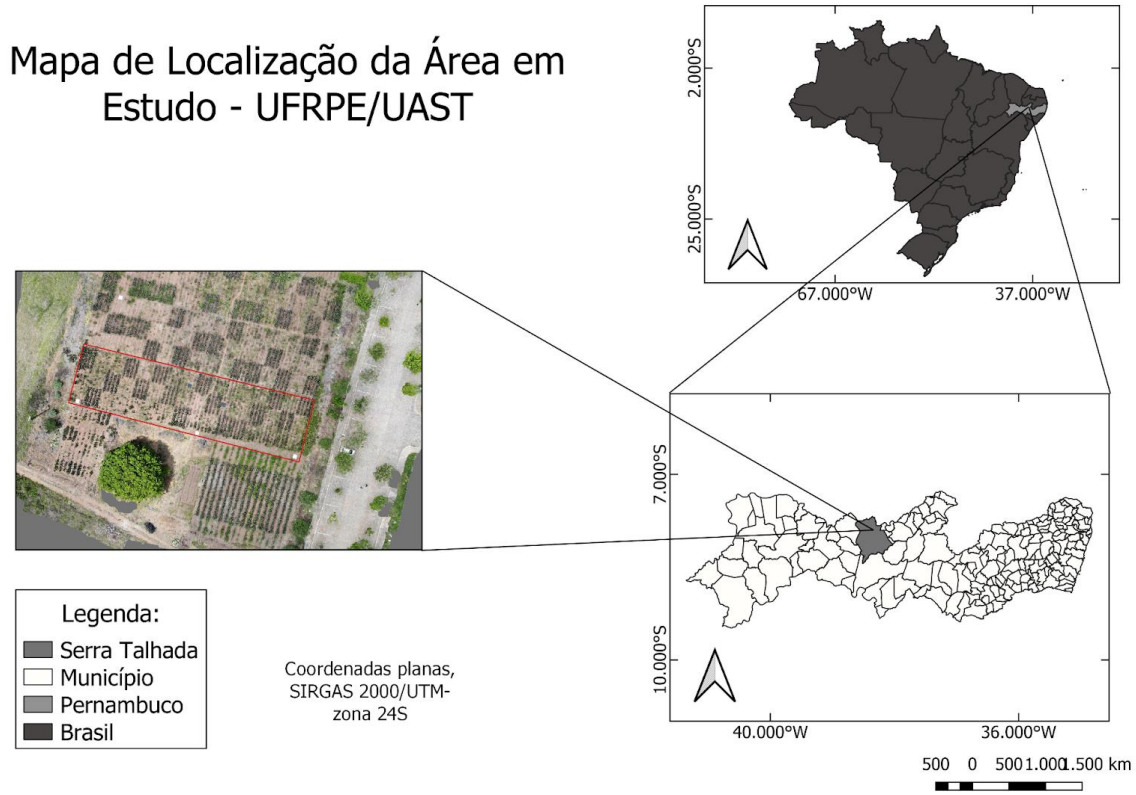


Figura 1 - Mapa de Localização da área experimental.

O experimento apresentou áreas com cultivo de palma forrageira dos clones Orelha de elefante (OEM) pertencentes ao gênero Opuntia sp. e IPA e Miúda pertencentes ao gênero Nopalea sp.. Contudo, este estudo avaliou apenas a clone orelha de elefante, uma vez que os demais clones apresentaram alta mortalidade, dificultando o seu monitoramento ao longo do experimento. Dessa forma, escolheu-se apenas uma planta (OEM), durante o período de avaliação, georreferenciado com sistema de posicionamento por GNSS RTK (Modelo Stonex 850a), para obter os valores dos pixels nos diferentes índices de vegetação obtido com o VANT e coleta do índice de área do cladódio (IAC).

3.2 Banco de dados

A fenologia da cultura foi monitorada ao longo dos meses de abril a novembro de 2022 através de dados biométricos usados para estimativa da área do cladódio e do índice de área foliar do cladódio (IAC). A partir das informações coletadas da biometria, tais como altura, largura, espessura, número de cladódios, estimou-se a índice de área do cladódio com base no estudo de Pinheiro et al. (2015).

Para registro das imagens utilizou-se um veículo aéreo não tripulado (VANT) modelo DJI Mavic 2 Enterprise Dual, que apresenta autonomia de voo de aproximadamente 30 minutos, tipo quadricóptero com GPS, equipado com uma câmera RGB e Termal.

O imageamento sobre as áreas de estudo ocorreu em condições de iluminação consistentes, sempre na faixa das 13h em dias claros e ensolarados. As imagens foram obtidas uma vez nos meses: Abril, maio, junho, julho, agosto, setembro, outubro e novembro, utilizando a câmera na banda do visível (RGB) a bordo do VANT. Para obter os melhores resultados, utilizou-se uma sobreposição de 90% de lateral e 90% de frontal (Arantes et al., 2020) e posicionado a uma altura de 40 metros. A partir das imagens coletadas no voo, foram processadas no programa Metashape Agisoft para a criação dos ortomosaicos.

A partir dos ortomosaicos obtidos com o sensor RGB a bordo do VANT, efetuou-se o georreferenciamento dessas imagens, em um software de sistema de informações geográficos Qgis versão da série 3.0, através da ferramenta georreferenciador. Utilizou-se o ambiente R para fazer o processamento das imagens e obtenção dos índices de vegetação, utilizando a interface do Rstudio, e o pacote FieldimageR (Matias, Caraza?Harter e Endelman, 2020). Os índices de vegetação utilizados estão disponíveis na Quadro 1 e foram apresentados por Freire-Silva et al. (2019) e Swaef et al. (2021).

Quadro 1 - Índices de vegetação e as respectivas equações de uso.

Índice	Sigla	Fórmula	Referência
Visible Atmospherically Resistant Index	VARI	g-rg+r-b	(Gitelson et al., 2002)
Modified Green Red Vegetation Index	MGRVI	g2-r2g2+r2	(Bending et al., 2015)
Green Leaf Algorithm	GLA	(2g-r-b)(2g+r+b)	(Louhaichi et al., 2001)
Green Red Vegetation Index	NGRDI	G-RG+R	Tucker (1979)
Excess Green Vegetation Index	ExG	2g-r-b	(Guijarro et al., 2011)
Excess Green Red Vegetation Index	ExGR	ExG-ExR	(Guijarro et al., 2011)
Vegetative	VEG	gr0.667*b0.333	(Hague, Tillett & Wheeler, 2006)
Combination	COM	0.25ExG+0.3ExGR+0.33CIVE+0.12VEG	(Guijarro et al., 2011)

Análise Estatística e Modelo

Por fim, coletou-se as respostas dos índices de vegetação proposto (Quadro 1) em nível de pixel na planta fixa durante o período de avaliação a partir do qual realizou-se uma correlação com o índice de área do cladódio (IAC). Em seguida, considerou-se os índices com correlação acima de 0,5 para seleção dos mais adequados na análise espacial e foram confeccionados mapas temáticos. Por fim, foram gerados modelos linear e quadrático com resposta espectral como variável independente e o IAC como variável dependente. Os modelos foram testados com uma significância ao nível de 5% para verificar o desempenho.

RESULTADOS E DISCUSSÃO

4.1 Estimativa de correlação entre os índices

A figura 2 apresenta os coeficientes de correlação para a OEM, cultivar presente na área estudada, do IAC com todos os índices de vegetação. Dentre os resultados encontrados, selecionou-se cinco índices que possuíam valores acima de 0.3, que foram: VARI (Índice de Resistência Atmosférica Visível); MGRVI (Índice de Vegetação Verde-Vermelho Modificado), COM (Índice de vegetação combinado), NGRDI (Índice de Vegetação Verde-Vermelho) e VEG (Índice de Vegetação Verde).

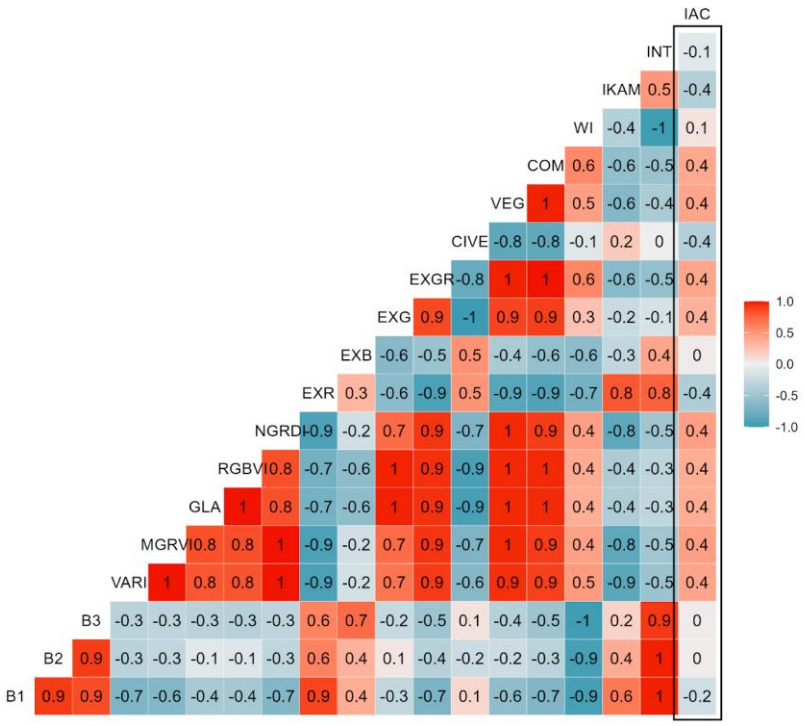


Figura 2 - Coeficientes de Correlação entre o índice de área do cladódio (IAC) e os índices de vegetação da palma Orelha de Elefante (OEM), destacado no retângulo preto.

Não há estudos aplicando esta análise com palma forrageira, contudo, é interessante destacar que GLA e EXGR apresentam bons resultados com outros tipos de forragens. Por exemplo, em um com azevém perene (Lolium perenne L.) e a festuca alta (Festuca arundinacea Schreb.), para avaliação de tolerância a estresse hídrico, Swaef et al. (2021) também encontraram correlações do GLA, denominadas por eles como Índice de Vegetação de Diferença de Banda Visível, e EXGR, com valores acima de 0,7, com um nível de avaliação da biomassa e coloração verde da planta. Além desses índices, os autores encontraram boas correlações com outros índices, como VARI, VEG, MGRVI, entre outros, com resultados acima de 0,7.

4.2 Mapas Temáticos

As Figuras 3, 4 e 5 apresentam a variabilidade espaço-temporal dos índices de vegetação com valores de correlação acima de 0,3. Destaca-se que na área de experimento há parcelas com diferentes clones de palma forrageira, como a orelha mexicana, IPA e a Miúda. Entre eles, os índices VARI (Figura 4) e VEG (Figura 5) caracterizam melhor os diferentes tipos de cobertura da vegetação e clones de palmas.

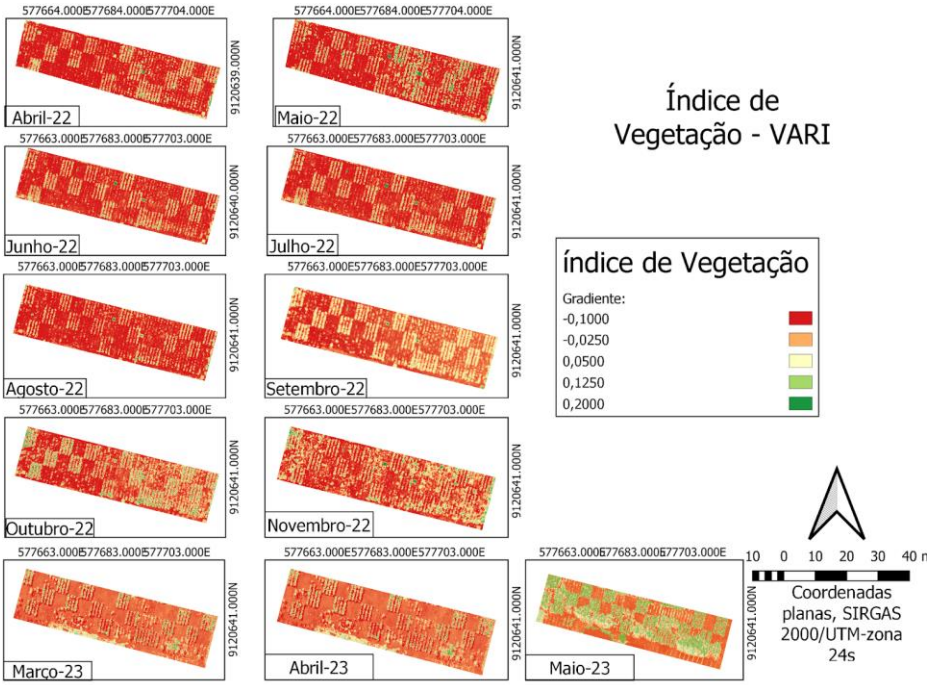


Figura 3 - Mapa de resistência atmosférica visível (VARI) entre os meses de Abril/22 á Maio/23

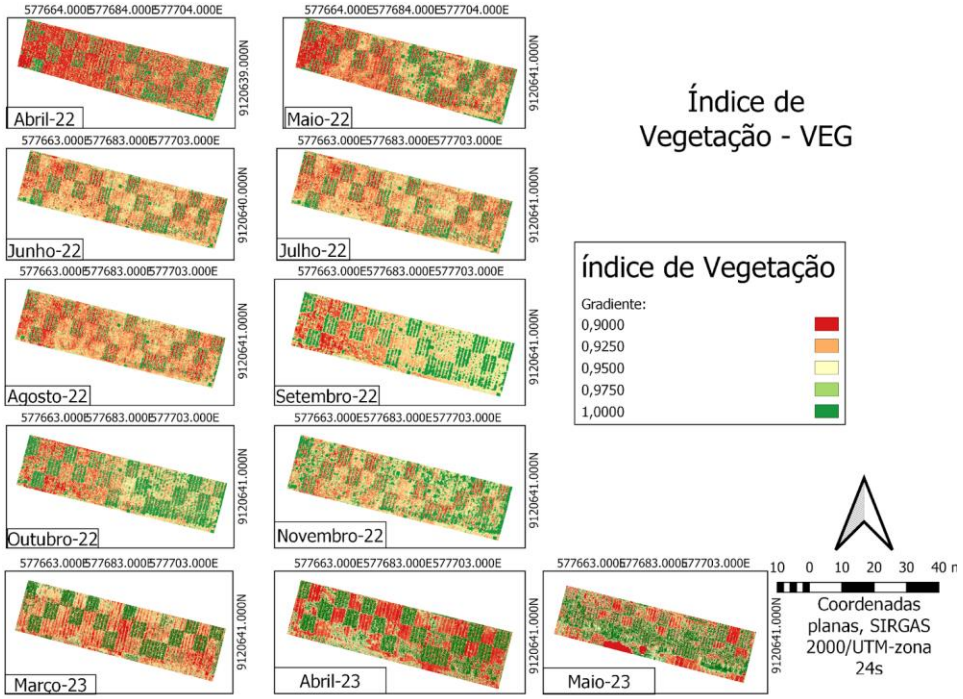


Figura 4 - Mapa de variabilidade espacial do índice de Vegetação verde (VEG) entre os meses de Abril/22 á Maio/23

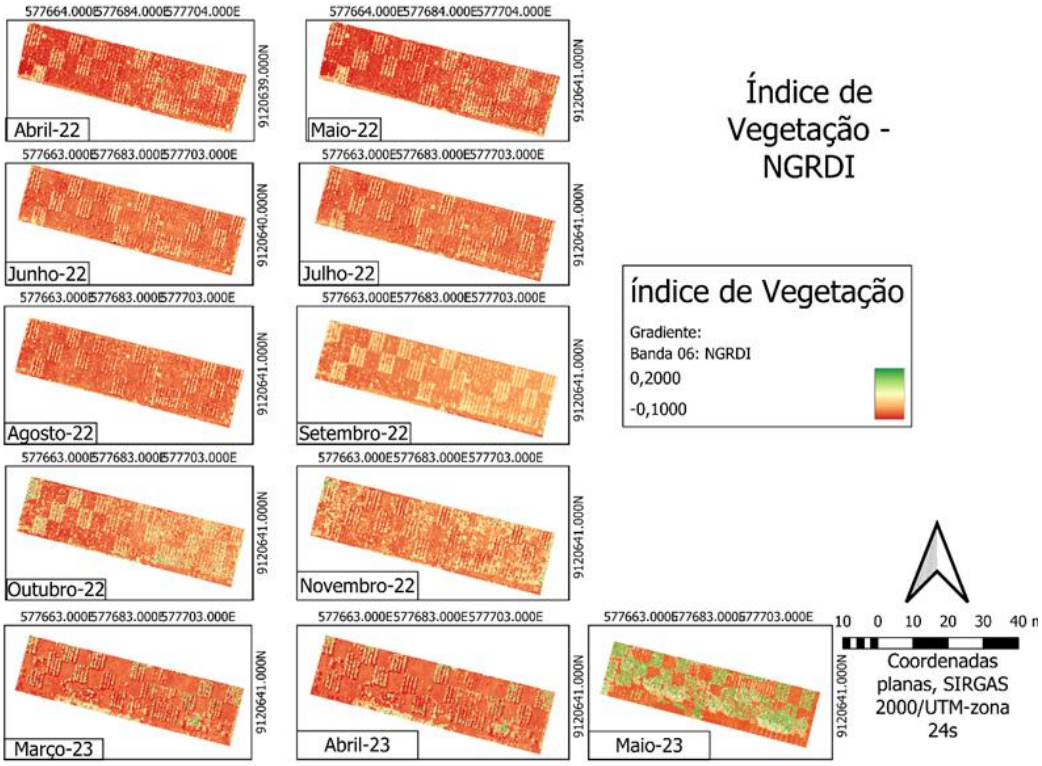


Figura 5 - Mapa de variabilidade espacial do índice de Verde vermelho (NGRDI) entre os meses de Abril/22 á Maio/23

Destaca-se que o VEG é um índice que permite boas segmentações das coberturas vegetais e solo, sendo usado para classificar e diferenciar vegetação e solo exposto usando imagens coloridas que não dependem tanto do grau de luminosidade (Hague, Tillett & Wheeler, 2006). Além disso, o MGRVI ainda possui semelhança do próprio NGRDI dentro do seu modelo, dessa forma, a capacidade de segmentação das classes de cobertura são equiparáveis.

4.3 Regressão dos índices IAC

4.3.1 Teste de Regressão linear

Observa-se que o resultado da regressão linear feito com a palma OEM não apresenta ajuste (Figura 6), apresentando índices de determinação (r^2) na ordem 0,18. Além disso, o P-valor encontrado foi de 0,13 a 0,15 para todos os modelos, dessa forma, não se adequa ao nível de 5% desejado e aceita-se hipótese nula da correlação na regressão linear.

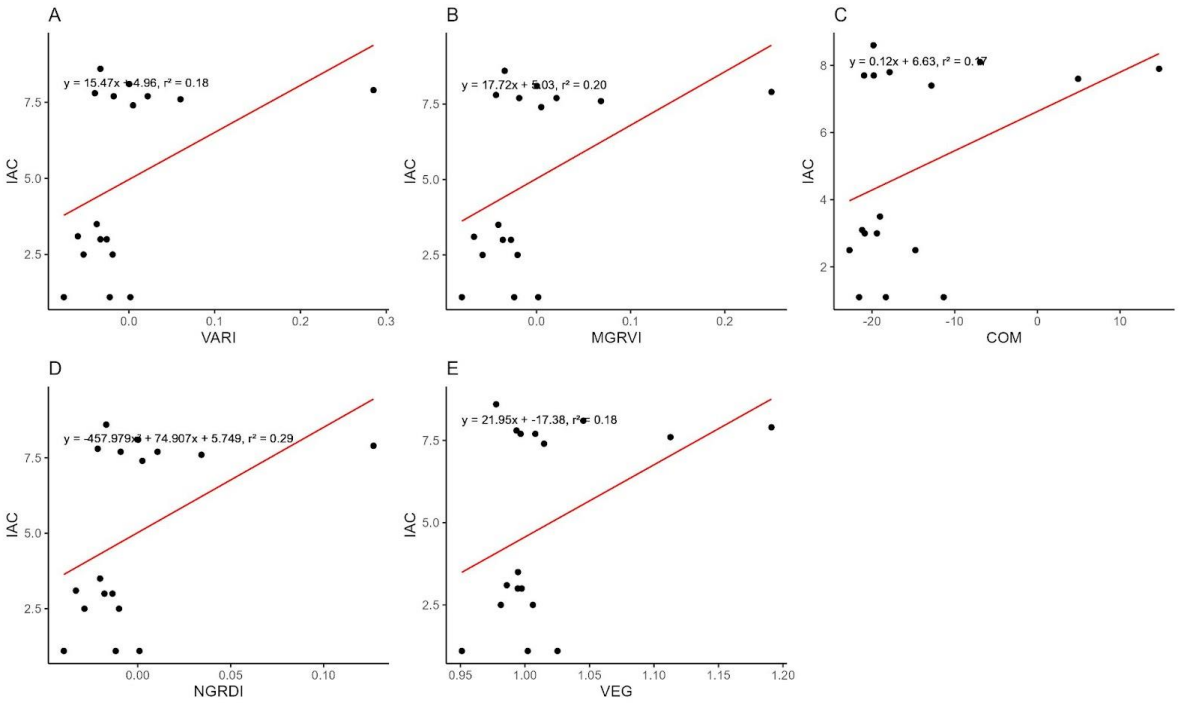


Figura 6 - Gráfico de regressão linear comparando o IAC biométrico com os índices de vegetação: (A) VARI; (B) MGRVI; (C) COM; (D) NGRDI; (E) VEG

4.3.2 Teste de Regressão quadrática

Considerando um modelo quadrático, também não tiveram modificação no seu ajuste para os índices selecionados (Figura 7). Estes modelos apresentam coeficientes de determinação de 0,29, em F, G e I, enquanto o modelo com base no COM e VEG possuem um coeficiente respectivamente de 0,17 e 0,20 não tão diferente do modelo linear.

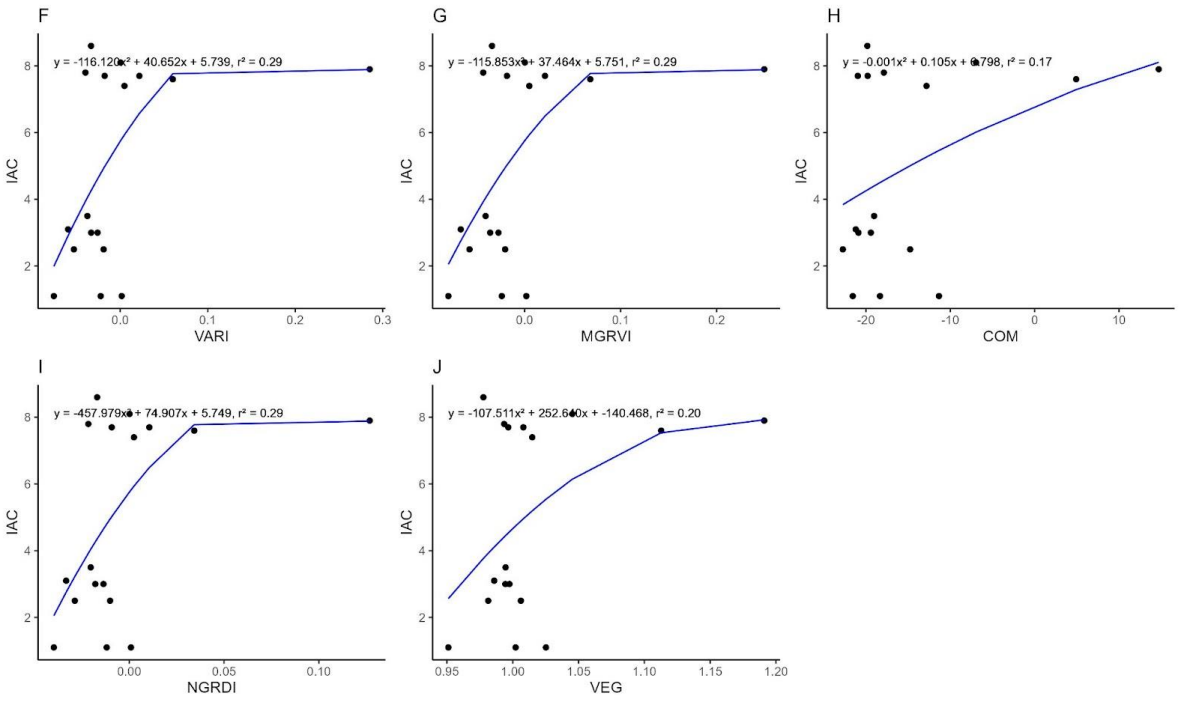


Figura 7 - Gráfico de modelo quadrático comparando o IAC biométrico com os índices de vegetação: (F) VARI; (G) MGRVI; (H) COM; (I) NGRDI; (J) VEG.

Os modelos MGRVI e NGRDI possuem algumas características em comum, pois apresentam as bandas do verde e vermelho em sua composição. Desse modo, com a utilização de vários outros espectros em conjunto no mesmo índice, esses dois modelos podem ser considerados equivalentes. Diante disso, os modelos apresentaram um ajuste próximo em função das características dos índices.

Em um experimento desenvolvido por Da Silva et al. (2021), encontraram um bom ajuste para um modelo linear com resultados da imagem Sentinel-2 para estimativa da cobertura vegetal de palmas forrageiras, avaliando, inclusive, clone da orelha de elefante. No entanto, a diferença do nível de resolução dos produtos Sentinel-2 (10 metros) e RGB em VANT's (centimétrica), pode justificar a diferença dos ajustes dos modelos.

Outro fator a considerar na falta de ajuste da regressão linear da clone OEM é devido às suas características morfológicas de emissão, tamanho, formato e distribuição dos cladódios, provocando diferentes coberturas do solo, impactando na resposta espectral da cultura. Ressalta-se que estas características foram significativas para estimativa do IAC, em especial a altura da planta e número de cladódios com o IAC (DA SILVA et al., 2021).

Os cladódios dos cactos forrageiros possuem formatos irregulares e variam em espessura ao longo do comprimento, o que dificulta a aplicação do método de estimar sua área fotossintética a partir dos índices, visto que sua espessura se encontra paralela ao solo e o limbo foliar lateralizado, com isso, torna-se um desafio ter uma boa imagem e fazer as predições (Pinheiro, et al., 2015). A variação significativa na área foliar específica em relação a clones, idade e posição na planta pode ser a razão para o desempenho inferior em alguns métodos. Esses resultados contrastam com os de Souza et al. (2012), que compararam métodos de medição de área foliar em culturas de melancia.

CONCLUSÃO

Este projeto busca investigar a resposta espectral de índices de vegetação no visível da palma forrageira a partir de sensores RGB em veículos aéreos não tripulados (VANTs). Com os resultados obtidos até então, os índices VARI (Mapa de resistência atmosférica visível); VEG (Índice de Vegetação Verde) e NGRDI (Índice de Vegetação Verde-Vermelho) não apresentaram correlações satisfatória com IAC, tendo valores abaixo de 0,5. Entretanto, foi possível ter uma boa visualização da variabilidade espacial da palma. Ao analisar a regressão linear destes índices com o Índice de Área de Cladódio (IAC), não apresentaram ajuste significativo ($r^2 < 0,3$). Por sua vez, na análise de regressão quadrática, os resultados foram semelhantes e não houve mudanças consideráveis para essa modelagem.

REFERÊNCIAS

ÁLVARES, C. A; STAPE, J. L; SENTELHAS, P. C; GONÇALVES, J. D. M; SPAROVEK, G. Mapa de classificação climática de Köppen para o Brasil. Meteorologische Zeitschrift, v. 22, n. 6, p. 711-728, 2013.

ARANTES, L. T.; ARANTES, B. H. T.; GIONGO, P. R.; CECCATO, G. Z; MORAES, V. H.; SAITO, Y. K.; GOMES, L. F; DE OLIVEIRA CASTRO, A. C. Comportamento espectral e detecção de laranjeiras (Citrus sinensis L. Osbeck) com estresse hídrico, por meio de drone. Revista Brasileira de Geografia Física, v. 13, n. 7, p. 3625-3635, 2020.

BARBOSA, B. D. S.; FERRAZ, G. A. S.; GONÇALVES, L. M.; MARIN, D. B.; MACIEL, D. T.; FERRAZ, P. F. P.;ROSSI, G. RGB vegetation indices applied to grass monitoring: a qualitative analysis. Agronomy Research, v. 17, n. 2, p. 349-357, 2019.

BENDIG, J.; YU, K.; AASEN, H.; BOLTEN, A.; BENNERTZ, S.; BROSCHEIT, J.; BARETH, G. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. International Journal of Applied Earth Observation and Geoinformation, v. 39, p. 79-87, 2015. DOI: https://doi.org/10.1016/j.jag.2015.02.012.

CAMARGO NETO, J. A combined statistical-soft computing approach for classification and mapping weed species in minimum -tillage systems. Dissertação- University of Nebraska - Lincoln. 2004. Disponível em: https://digitalcommons.unl.edu/dissertations/AAI3147135. Acesso em: 14 fev 2023.

DA COSTA, S. A. T.; BEZERRA, A. C.; DE ARAÚJO, A. M. Q.; DA SILVA, M. F.; NETO, J. F. D. C.; ALVES, R. M.; DE SOUZA, L. S. B. Dinâmica espaço-temporal das anomalias de precipitação em uma região semiárida, Nordeste do Brasil. Revista de Gestão de Água da América Latina, v. 18, n. 2021, 2021.

DA SILVA, M. V.; PANDORFI, H.; DE ALMEIDA, G. L. P.; DE LIMA, R. P.; DOS SANTOS, A.; JARDIM, A. M. D. R. F.; ROLIM M. M; DA SILVA, J. L. B.; BATISTA, P. H. D.; DA SILVA, R. A. B.; LOPES, P. M. O.; DA SILVA, D. C. Spatio-temporal monitoring of soil and plant indicators under forage cactus cultivation by geoprocessing in Brazilian semi-arid region. Journal of South American Earth Sciences, v. 107, p. 103155, 2021.

DE SWAEF, T.; MAES, W. H; APER, J.; BAERT, J.; COUGNON, M.; REHEUL, D.; STEPPE, K.; ROLDÁN-RUIZ, I.; LOOTENS, P. Applying RGB-and thermal-based vegetation indices from UAVs for high-throughput field phenotyping of drought tolerance in forage grasses. Remote Sensing, v. 13, n. 1, p. 147, 2021.

FANG, H.; LI, W.; WEI, S.; JIANG, C. Seasonal variation of leaf area index (LAI) over paddy rice fields in NE China: Intercomparison of destructive sampling, LAI-2200, digital hemispherical photography (DHP), and AccuPAR methods. Agricultural and Forest Meteorology, v. 198, p. 126-141, 2014.

FREIRE-SILVA, J.; PAZ, Y. E.; LIMA-SILVA P. P.; PEREIRA, J. A. S.; CANDEIAS, A. L. B. Índices de vegetação do sensoriamento remoto para processamento de imagens na faixa do visível (RGB). Journal of Hyperspectral Remote Sensing, v. 9, p. 228-239, 2019.

GITELSON, A. A.; KAUFMAN, Y. J.; STARK, R.; RUNDQUIST, D. Novos algoritmos para estimativa remota de fração de vegetação. Sensoriamento remoto de Ambiente, v. 80, n. 1, p. 76-87, 2002.

GOWARD, S. N; MARKHAM, B.; DYE, D. G; DULANEY, W.; YANG, J. Normalized difference vegetation index measurements from the Advanced Very High Resolution Radiometer. Remote sensing of environment, v. 35, n. 2-3, p. 257-277, 1991.

GUIJARRO, M.; PAJARES, G.; RIOMOROS, I.; HERRERA, P. J.; BURGOS-ARTIZZU, X. P.; RIBEIRO, A. Automatic segmentation of relevant textures in agricultural images. Computers and Electronics in Agriculture, v. 75, n. 1, p. 75-83, 2011. DOI: https://doi.org/10.1016/j.compag.2010.09.013.

HAGUE, T.; TILLETT, N. D.; WHEELER, H. Automated crop and weed monitoring in widely spaced cereals. Precision Agriculture, v. 7, p. 21-32, 2006. DOI: https://doi.org/10.1007/s11119-005-6787-1.

JARDIM, A. M. DE R. F. Consórcios de palma (Nopalea sp. e Opuntia sp.) em sistema de plantio adensado com cultivares de sorgo sob uso mínimo e regular de irrigação. Dissertação (Programa de Pós-Graduação em Produção Vegetal). 127p. Universidade Federal Rural de Pernambuco, 2019.

LINS, F. A. C; DA SILVA, J. L. B; DE ALBUQUERQUE MOURA, G. B; ORTIZ, P. F. S; OLIVEIRA, J. D. A; ALVES, M. V. C. Técnica quantílica para precipitação, índice de anomalia de chuva e parâmetros biofísicos por sensoriamento remoto em Serra Talhada, Pernambuco. Journal of Hyperspectral Remote Sensing, v. 7, n. 6, p. 334-344, 2017.

LOUHAICHI, M.; BORMAN, M. M.; JOHNSON, D. E. Spatially Located Platform and Aerial Photography for Documentation of Grazing Impacts on Wheat. Geocarto International, v. 16, n. 1, p. 65-70, 2001.

MATIAS, F. I.; CARAZA-HARTER, M. V.; ENDELMAN, J. B. FIELDimageR: An R package to analyze orthomosaic images from agricultural field trials. The Plant Phenome Journal, v. 3, n. 1, 2020.

MEYER, G. E.; NETO, J. C. Verification of color vegetation indices for automated crop imaging applications. Computers and electronics in agriculture, v. 63, n. 2, p. 282-293, 2008. DOI: https://doi.org/10.1016/j.compag.2008.03.009.

PESSI, D. D.; BELIN, R. B.; JUNIOR, P. L. M.; DA SILVA, N. M. Aeronaves remotamente pilotadas e suas aplicações no manejo agrícola e ambiental. Cadernos de Ciências & Tecnologia, v. 37, n. 2, e-26605, 2020.

PINHEIRO, K. M.; SILVA, T. G. F. D.; DINIZ, W. J. D. S.; CARVALHO, H. F. D. S.; MOURA, M. S. B. D. Indirect methods for determining the area index of forage cactus cladodes. Pesquisa Agropecuária Tropical, v. 45, p. 163-171, 2015.

R CORE TEAM. R Development Core Team. R: A Language and Environment for Statistical Computing, 2019.

SAMPAIO, H. S.; BOURSCHEIDT, V.; SARRACINI, L. H.; JORGE, L. D. C.; BETTIOL, G. M.; BERNARDI, A. D. C. Comparação entre índices de vegetação obtidos por imagens aéreas com veículo aéreo não tripulado (VANT) e satélite. Brazilian Journal of Biosystems Engineering, v. 14, n. 2, p. 111-124, 2020.

SANTOS, K. C; MAGALHÃES, A. L. R; SILVA, D. K. A; ARAÚJO, G. G. L; FAGUNDES, G. M.; YBARRA, N. G.; ABDALLA, A. L. Potencial nutricional de espécies forrageiras encontradas no semiárido brasileiro. Pecuária ciência, v. 195, p. 118-124, 2017.

SHIGETO, K.; MAKOTO, N. An algorithm for estimating chlorophyll content in leaves using a video camera. Annals of Botany, v. 81, n. 1, p. 49-54, 1998.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. Remote Sensing of Environment, v. 8, n. 2, p. 127-150, 1979.

WOEBBECKE, D. M.; MEYER, G. E.; VON BARGEN, K.; MORTENSEN, D. A. Color indices for weed identification under various soil, residue, and lighting conditions. Transactions of the ASAE, v. 38, n. 1, p. 259-269, 1995.

MONITORAMENTO DA VARIABILIDADE ESPACIAL DA PRODUTIVIDADE DE POMARES DE CITROS BASEADA EM SENSORES ÓPTICOS E INTELIGÊNCIA ARTIFICIAL

PEDRO AUGUSTO MARAZZO DE SOUSA [2]; JOÃO MARCELO VIEIRA ALVES FILHO [1]; PAULO SOUZA RIBEIRO [2]; MATEUS PEREIRA GONZATTO [4]; LUCAS DE PAULA CORRÊDO [4]

[1]Bolsista. Laboratório de Agricultura Digital, Depto. de Agronomia, Universidade Federal de Viçosa, UFV, Viçosa ? MG. Universidade Federal de Viçosa; [2]Mestrando. Laboratório de Agricultura Digital, Depto. de Agronomia, Universidade Federal de Viçosa, UFV, Viçosa ? MG. Universidade Federal de Viçosa; [3]Doutorando. Laboratório de Agricultura Digital, Depto. de Agronomia, Universidade Federal de Viçosa, UFV, Viçosa ? MG. Universidade Federal de Viçosa; [4]Docente. Laboratório de Agricultura Digital, Depto. de Agronomia, Universidade Federal de Viçosa, UFV, Viçosa ? MG. Universidade Federal de Viçosa

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A produção de mapas de produtividade na citricultura permitirá ganhos inestimáveis para a gestão localizada de pomares utilizando técnicas de agricultura de precisão. O presente estudo buscou avaliar um método de mapeamento de produtividade de citros baseado na aquisição de imagens digitais de pomares obtidas por sensoriamento remoto e proximal óptico, e técnicas de aprendizado de máquina. A área de estudo foi composta por 19 pomares comerciais. Dados de sensoriamento remoto, e de sensoriamento proximal, utilizando um sensor imageador comercial, foram obtidos imediatamente antes da colheita. Durante a colheita, os sacolões foram georreferenciados, e os mapas de produtividade foram produzidos por meio de geoprocessamento e geoestatística. Os dados foram compilados e segmentados em conjunto de treino (14 talhões) e teste (5 talhões), para desenvolvimento do modelo de predição *Random forest*. O modelo apresentou acurácia de 0,32 ton ha^{-1}, entretanto não foi eficiente na estimativa de talhões com produtividade inferior a 20 ton ha^{-1}, subestimando a produtividade. Estudos futuros devem ser realizados para avaliar algoritmos alternativos, como modelos de classificação.

PALAVRAS-CHAVE: Agricultura digital; Mapas de produtividade; Geoprocessamento

ABSTRACT

The production of yield maps in citrus cultivation will allow invaluable gains for the localized management of orchards using precision agriculture techniques. This study aimed to evaluate a method for mapping citrus yield based on the acquisition of digital orchard images obtained through remote and proximal optical sensing, along with machine learning techniques. The study area consisted of 19 commercial orchards. Remote sensing data and proximal sensing data, using a commercial imaging sensor, were obtained immediately before harvest. During harvest, fruit bins were georeferenced, and productivity maps were produced through geoprocessing and geostatistics. The data were compiled and segmented into training (14 orchards) and testing sets (5 orchards) to develop the Random Forest prediction model. The model showed an accuracy of 0.32 ton ha^{-1}; however, it was not efficient in estimating orchards with productivity lower than 20 ton ha^{-1}, underestimating yield. Future studies should be conducted to evaluate alternative algorithms, such as classification models.

KEYWORDS: ;;

INTRODUÇÃO

Os setores envolvidos na produção vegetal de produtos hortícolas, de forma geral, carecem de tecnologia aplicada à gestão da variabilidade espacial da produtividade. Este fato constitui o primeiro entrave para a adoção de técnicas de agricultura de precisão (AP). A citricultura ocupa lugar de destaque na economia brasileira. O país é o maior produtor mundial de laranja e o maior exportador do suco, representando 75% do mercado global da bebida (IBGE, 2023). Diante deste cenário, torna-se evidente o potencial da inserção de técnicas de AP para otimização do uso de insumos de produção e maior sustentabilidade da atividade. Faz-se necessário, portanto, a consolidação de técnicas robustas para mapeamento da produtividade de pomares. No Brasil, em virtude de limitações e diferenças operacionais na colheita, a obtenção de mapas de produtividade foi proposta via diferentes metodologias, sendo que Balastreire et al. (2002), Parise (2004) e Farias et al. (2003) exploraram tal assunto. Dentro da metodologia proposta por Farias et al. (2003), os talhões produtivos foram georreferenciados, sendo que a produtividade foi obtida pela amostragem de plantas dentro de cada talhão para características como número, massa e tamanho de frutos e a posterior manipulação geoestatística desses dados via krigagem. Já nesse cenário, foi possível identificar a variabilidade espacial entre os diferentes talhões e comprovar o potencial da utilização de dados georreferenciados e da aplicação de geoestatística para o mapeamento da produtividade na citricultura. Outros trabalhos avaliaram técnicas manuais de mapeamento da produtividade (MOLIN e MASCARIN, 2007; COLAÇO et al., (2020), permitindo a consolidação de uma técnica efetiva, por meio do georreferenciamento de "sacolões" (*bags*), utilizados para colheita e transporte dos frutos. Colaço et al. (2020) avaliaram dois métodos de interpolação e o impacto da acurácia de posicionamento na qualidade dos mapas obtidos. Os autores concluíram que em situações normais de campo, com erros de posicionamento e massa dos *bags* abaixo de 1 m e 5%, as abordagens tiveram desempenho semelhante, com níveis de precisão variando entre 5 e 11 Mg ha^{-1}, dependendo da variabilidade espacial da produtividade. Entretanto, apesar de consolidar-se como uma metodologia simples e efetiva, outros estudos tem utilizado visão computacional e métodos indiretos para quantificação de frutos (HE et al., 2022). Este estudo buscou avaliar um método híbrido de mapeamento de produtividade baseado na aquisição de imagens digitais de pomares de citros obtidas por sensoriamento remoto (indireto) e proximal óptico (direto) e técnicas de aprendizado de máquina.

OBJETIVOS

Este estudo buscou avaliar um método híbrido de mapeamento de produtividade baseado na aquisição de imagens digitais de pomares de citros obtidas por sensoriamento remoto (indireto) e proximal óptico (direto) e técnicas de aprendizado de máquina.

MATERIAL E MÉTODOS

Todos os dados foram coletados em pomares comerciais, no município de Santa Cruz do Rio Pardo - SP. A área de estudo foi composta por 23 talhões, com área total de 246 hectares, plantados há cinco anos com laranja da variedade Pêra com espaçamento de 6,8 x 2,5 m. Destes, treze talhões foram plantados com o porta-enxerto Sunki e seis com o porta-enxerto Cleópatra.

Os dados de produtividade foram gerados através da metodologia descrita por Molin e Mascarin (2007). Durante a colheita os sacolões (*Big bags*) dispostos à campo, com peso aproximado de 0,5 toneladas, foram georreferenciados através de um receptor GNSS de navegação (Garmin GPSMAP® 60CSxd). A partir dos mapas de pontos georreferenciados, foram gerados polígonos de Voronoi determinando a área de influência de cada *bag*. Cada coordenada foi modificada para o centroide de cada polígono, e calculada a relação de massa colhida por área (Figura 1). Em seguida, foi realizada a análise geoestatística com modelagem do semivariograma de produtividade para cada talhão, e os dados foram interpolados por krigagem ordinária.

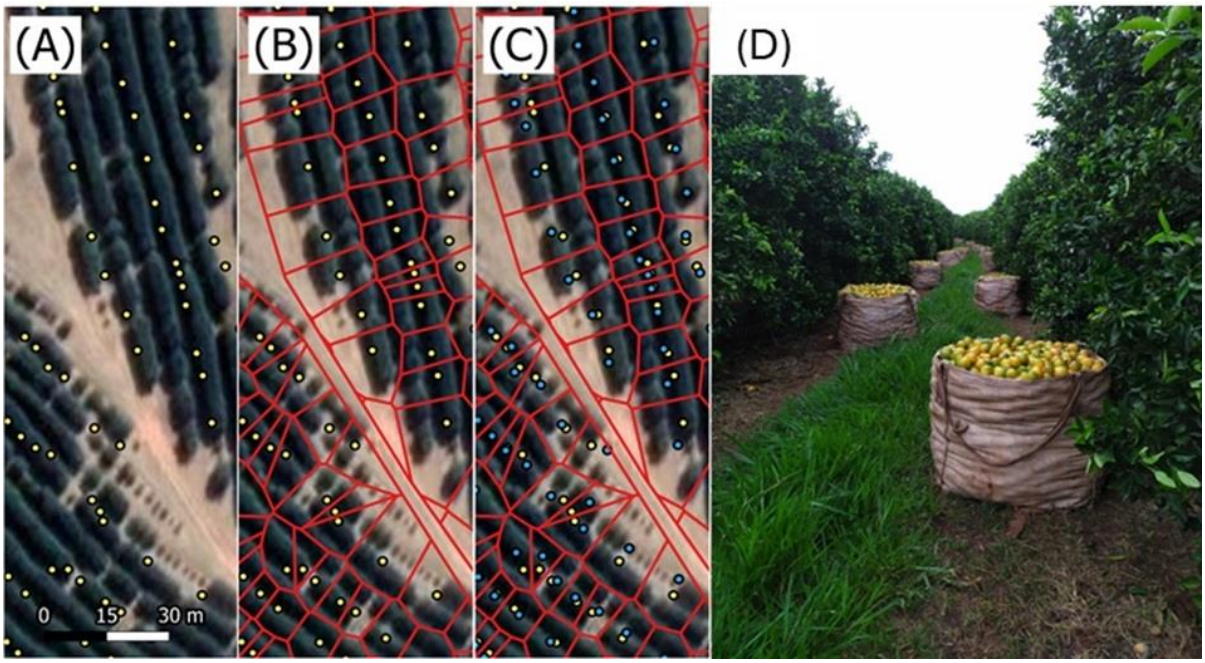


FIGURA 1. (A) Pontos referentes aos sacolões dispostos à campo; (B) polígonos de Voronoi gerados com base nos sacolões georreferenciados, representando a área de influência estimada para cada sacolão; (C) Composição com os pontos dos sacolões (em amarelo) e os centróides dos polígonos de voronoi (em azul); (D) Sacolões utilizados na colheita.

Imagens de satélite foram obtidas através dos sensores da constelação Planet Scope (PBC, 2018) com resolução espacial de três metros e resolução temporal diária. Durante o ciclo produtivo, foram coletadas 32 imagens com amplitude de junho a dezembro de 2022. As imagens foram organizadas e recortadas para a região de interesse e utilizadas para o cálculo de índices de vegetação. Os índices utilizados foram o Índice de Vegetação da Diferença Normalizada (NDVI) (TUCKER, 1979), Índice de Vegetação da Diferença Normalizada Verde (GNDVI) (GITELSON; KAUFMAN; MERZLYAK, 1996), Índice Foliar Verde (GLI) (LOUHAICHI; BORMAN; JOHNSON, 2001), Índice de Água de Diferença Normalizada (NDWI) (MCFEETERS, 1996) e Índice de Diferença Normalizada do Vermelho-limítrofe (NDRE) (TUCKER, 1979). Além disso, Modelos Digitais de Elevação (MDE) foram utilizados para a obtenção de dados de declividade e de altitude cálculo das horas média de incidência solar. Além dos índices de vegetação, as bandas vermelha (R), verde (G), azul (B), e infravermelho-próximo (NIR) foram utilizadas como variáveis. Os MDE foram obtidos através da plataforma ASF Data Search e foram coletados pelo satélite ALOS por meio do sensor PALSAR, com resolução espacial de 12,5 metros.

Os dados coletados via sensoriamento proximal tiveram como base o sensor óptico comercial LeafSense (Adroit Robotics, São Paulo, Brasil). O sensor foi embarcado em um trator agrícola e utilizado para coletar imagens georreferenciadas das faces laterais das árvores à medida que o veículo percorreu as entrelinhas dos talhões, imediatamente antes da colheita dos frutos. As imagens foram processadas por algoritmos baseados em *machine learning* de modo a extrair os atributos quantidade de frutos verdes, quantidade de frutos maduros, quantidade de frutos caídos no chão, quantidade de frutos a ser colhida (quantidade de frutos maduros + frutos caídos no chão), diâmetro dos frutos e densidade foliar. A partir dos dados georreferenciados do sensor LeafSense, foram extraídas e compiladas as informações das camadas de dados anteriores, formando a base de dados para o estudo.

Os valores máximos e mínimos foram utilizados para segmentar os dados, agrupados por talhões, em conjunto de treino (70%) e validação (30%). O modelo de regressão *Random Forest* (RF) foi criado usando 1000 árvores (ntree = 1000), e o número mínimo de amostras necessárias para estar em um nó de folha igual a 30. Em cada árvore, o RF usa a aleatoriedade no processo de regressão, selecionando um subconjunto aleatório de variáveis (mtry) para determinar a divisão (a seleção

aleatória das variáveis) em cada nó. A avaliação da acurácia dos modelos foi baseada nas métricas erro médio absoluto (MAE), raiz quadrada do erro médio (RMSE) e coeficiente de determinação (R^2). Todo o procedimento foi feito através de linguagem de programação *python 3.0*, utilizando a biblioteca *sklearn*.

RESULTADOS E DISCUSSÃO

A área de estudo apresentou uma variabilidade expressiva na produtividade (Figura 2). A área, composta por seis talhões na direção sudoeste, apresentaram baixa produtividade por se tratar de áreas compostas pelo porta-enxerto Cleópatra (abaixo de 26 ton ha^{-1}). Nas demais regiões, compostas por áreas com porta-enxerto Sunki, o desempenho produtivo foi maior. Com variabilidade de aproximadamente 26 a 98 ton ha^{-1} (Figura 3).

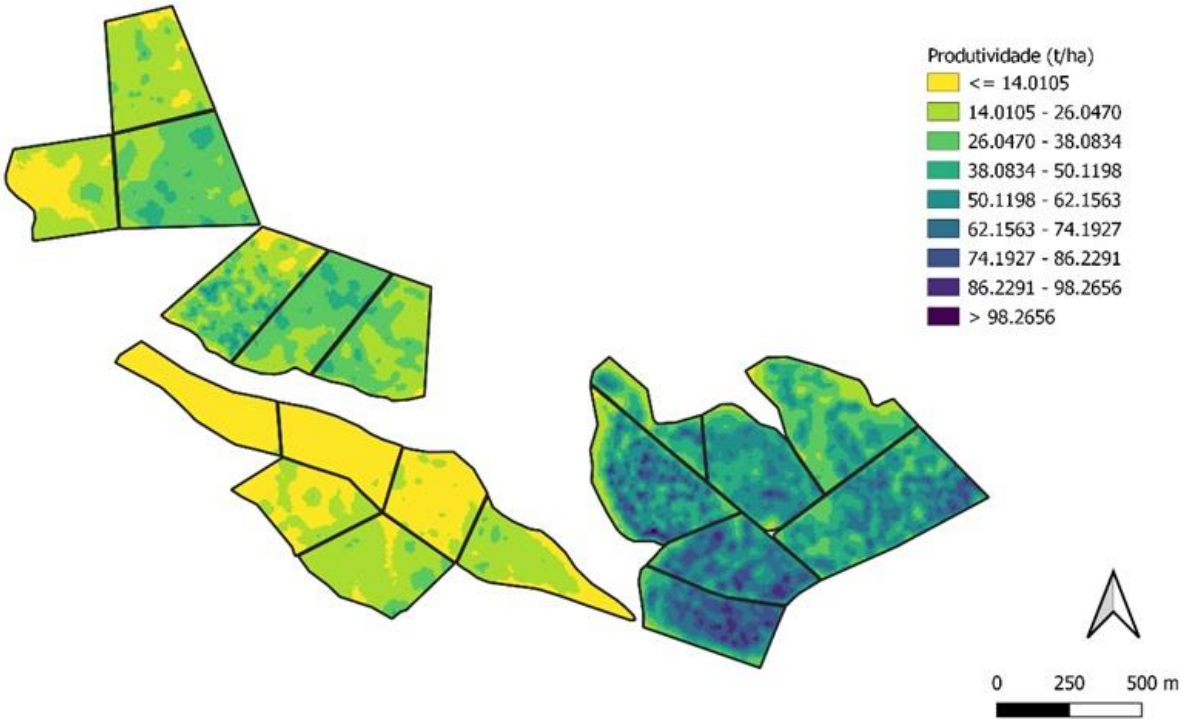


FIGURA 2. Variabilidade da produtividade da área de estudo.

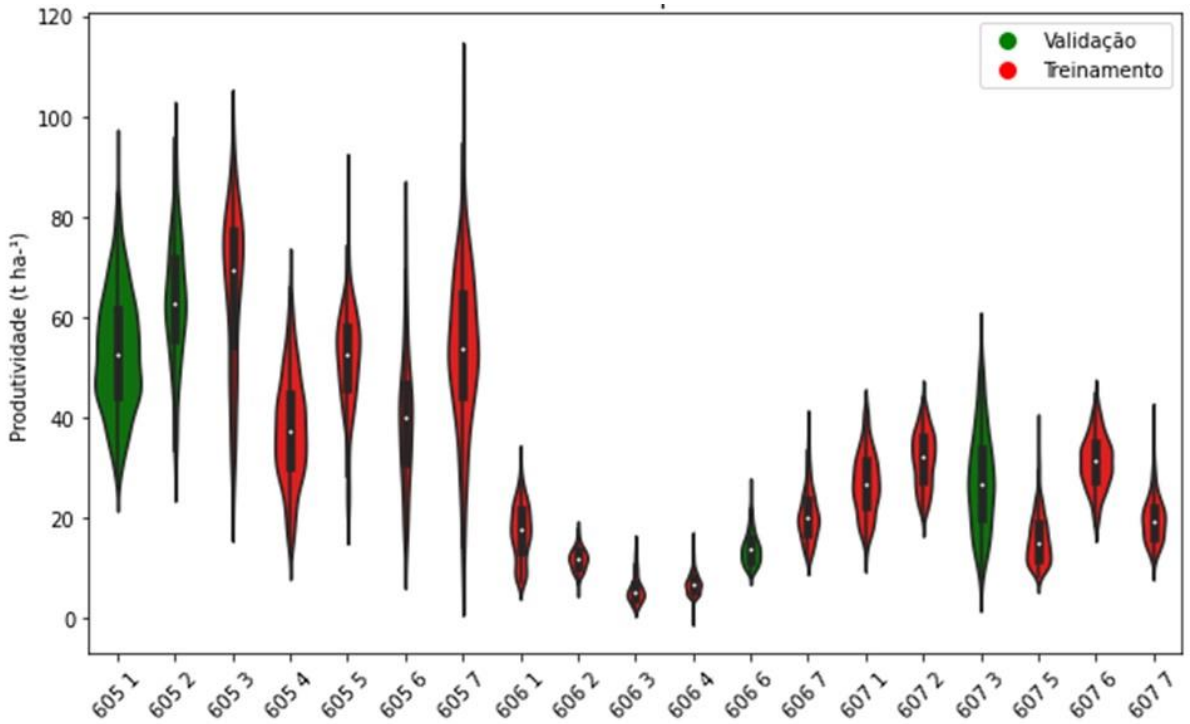


FIGURA 3. Variação de produtividade de cada talhão.

Entre as variáveis de sensoriamento remoto orbital, compostas por índices de vegetação e bandas espectrais, e de sensoriamento remoto proximal, baseadas na extração de atributos de imagens por meio de inteligência artificial, destaca-se a importância da variável "frutos colhidos" (Figura 4), seguido pela informação de porta-enxerto. As duas primeiras variáveis representaram cerca de 48% e 26%, respectivamente, da importância na modelagem preditiva. A variável frutos colhidos representa a contagem de frutos maduros, sem anomalias, no chão e nas árvores, visualizados e identificados pelo sensor comercial LeafSense utilizando técnicas de inteligência artificial. Entre as demais variáveis, destacam-se ainda o índice de vegetação EVI, densidade foliar e o NDVI. Juntas, as três variáveis representaram 19% de importância na predição dos valores de produtividade.

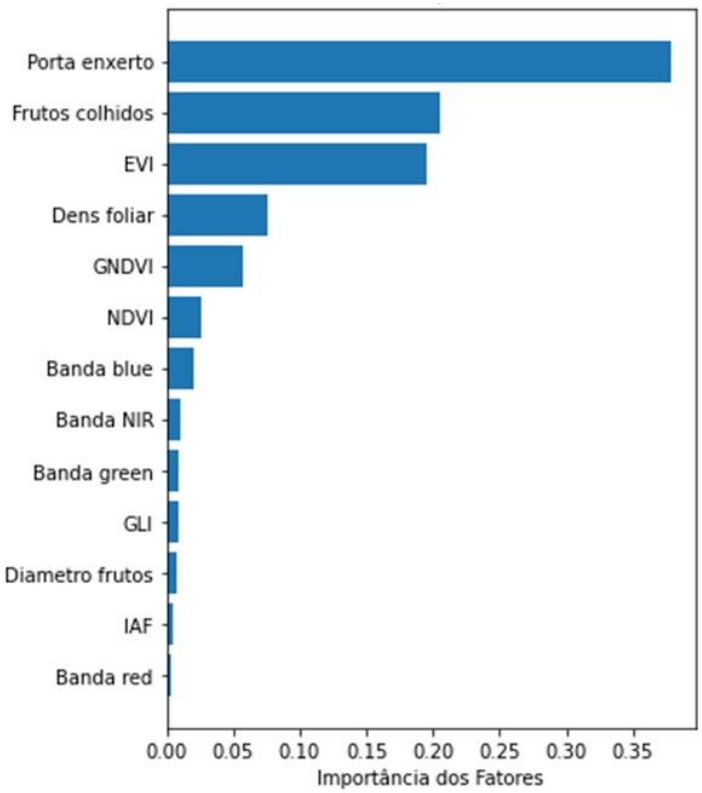


FIGURA 4. Importância das variáveis utilizadas na predição.

As predições apresentaram, em média, um desvio (MAE) de cerca de 9,33 ton ha^{-1}. Além disso, os desvios médios das previsões do modelo em relação aos valores reais (RMSE) de 0,31 ton ha^{-1}. A proporção da variabilidade da produtividade predita que é explicada pelo modelo de regressão (R^2) foi de 0,76. De forma geral, os resultados foram inferiores aos obtidos por Bai et al. (2021), em modelos de predição *random forest* para predição de produtividade de maçã, com valores de RMSE igual a 19,9 kg por árvore e R^2 de 0,71, e inferiores ao estudo conduzido por Dorj et al. (2017), em que obtiveram R^2 de 0,93, utilizando processamento de imagens para contagem de frutos. Entretanto, vale ressaltar que os vários estudos conduzidos para predição de produtividade de forma direta ou indireta, como reportado por He et al. (2022), não tratam da análise da variabilidade espacial da produtividade de citros. O modelo desenvolvido neste estudo não apresentou desempenho satisfatório, principalmente para predição de valores de produtividade inferiores a 20 ton ha^{-1} (Figura 5). Como mencionado, a área de estudo foi composta por áreas com uma mesma variedade, porém com dois porta-enxertos diferentes. O modelo não apresentou desempenho satisfatório na predição de produtividade de áreas cultivadas com o porta-enxerto Cleópatra. Essas áreas foram caracterizadas por baixas produtividades, e menos pontos amostrais (*big-bags*) quando comparados às áreas cultivadas com porta-enxerto Sunki. Nossa hipótese é de que os modelos devem ser específicos, e não generalistas, quando se considera a variabilidade de aspectos relativos à fisiologia e manejo entre pomares.

TABELA 1. Estatísticas de avaliação de desempenho de modelos de aprendizado de máquina.

Dataset	MAE	RMSE	R^2
Validação	9,33	0,31	0,76

MAE: erro médio absoluto, RMSE: raiz quadrada do erro quadrático médio, R^2: coeficiente de determinação.

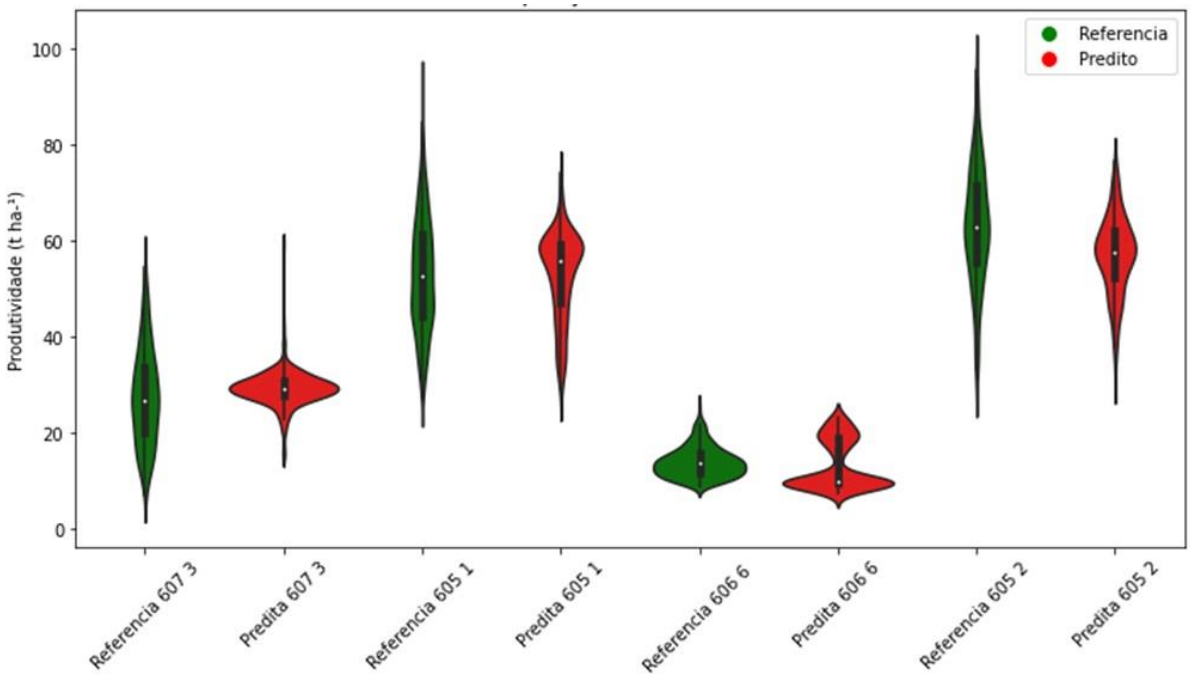


FIGURA 5. Gráfico de dispersão de produtividade observada e predita pelo modelo.

A quantificação da produtividade com elevada acurácia pode auxiliar citricultores na gestão da colheita, bem como na gestão de insumos de produção de forma localizada e caracterização de relações de causa e efeito, buscando aumentar a lucratividade e sustentabilidade da atividade. Apesar disso, um indicador indireto de variabilidade da produtividade pode ser suficiente para este fim. Estudos futuros serão conduzidos avaliando modelos de classificação para caracterização de padrões espaciais e identificação de regiões de maior e menor potencial produtivo. O uso de dados históricos de produtividade e de sensoriamento devem auxiliar neste objetivo. Além disso, análise de séries temporais de dados de sensoriamento remoto e climáticos, em estágios fenológicos chave da produtividade da cultura, podem auxiliar na previsibilidade desta caracterização.

CONCLUSÃO

O método proposto possibilitou mapear a variabilidade da produtividade dos pomares de citros com acurácia de 0,31 ton ha^{-1}. O método não foi assertivo para quantificação em áreas com produtividade inferior a 20 ton ha^{-1}, subestimando os valores neste intervalo.

AGRADECIMENTOS

À Fundação de Amparo à Pesquisa de Minas Gerais (FAPEMIG), pelo suporte financeiro por meio do projeto APQ-02529-22, e à Adroit Robotics pela parceria técnica no suporte às coletas em campo e conceção do sensor proximal utilizado no estudo.

REFERÊNCIAS

BALASTREIRE, L. A.; AMARAL, J. R.; ESQUERDO, J. C. D. M. Agricultura de precisão: mapeamento da produtividade de uma cultura de laranja. **Avanços na agricutlura de precisão no Brasil no periodo de 1999-2001**, 2002.

COLAÇO, A. F. et al. Yield mapping methods for manually harvested crops. **Computers and Electronics in Agriculture**, v. 177, p. 105693, 1 out. 2020.

DORJ, U. O.; LEE, M.; YUN, S. SEOK. An yield estimation in citrus orchards via fruit detection and counting using image processing. **Computers and Electronics in Agriculture**, v. 140, p. 103-112, 1 ago. 2017.

HE, L. *et al.* Fruit yield prediction and estimation in orchards: A state-of-the-art comprehensive review for both direct and indirect methods. **Computers and Electronics in Agriculture**, v. 195, p. 106812, 1 abr. 2022.

FARIAS, P. R. S. et al. SciELO - Brazil - Agricultura de precisão: mapeamento da produtividade em pomares cítricos usando geoestatística Agricultura de precisão: mapeamento da produtividade em pomares cítricos usando geoestatística.

GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, v. 58, n. 3, p. 289-298, 1996.

GREGO, C. R.; VIEIRA, S. R. Spatial variability of soil physical properties on an experimental plot. Revista Brasileira de Ciência do Solo, v. 29, p. 169-177, abr. 2005.

HOLLAND, K.H.; SCHEPERS, J. Use of a virtual-reference concept to interpret active crop canopy sensor data. **Precision Agriculture**, v.14, n.1, 2013.

HORROM, N. **Citrus yield monitoring and mapping**. International Society of Citriculture Congress. **Anais**...ISC Orlando, 2000.

LOUHAICHI, M.; BORMAN, M. M.; JOHNSON, D. E. Spatially Located Platform and Aerial Photography for Documentation of Grazing Impacts on Wheat. Geocarto International, v. 16, n. 1, p. 65-70, 2001.

MCFEETERS, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. International Journal of Remote Sensing, v. 17, n. 7, p. 1425-1432, 1 maio 1996.

MOLIN, J. P.; MASCARIN, L. S. Colheita de citros e obtenção de dados para mapeamento da produtividade. Engenharia Agrícola, v. 27, p. 259-266, abr. 2007.

PARISE, F. J. DE O. **Padrões de variabilidade espacial e temporal da produção em um pomar jovem de laranja Hamlin**. Thesis-[s.l.] Esalq, fev. 2004.

PBC, P. L. Planet Application Program Interface: In Space for Life on Earth. Disponível em: <https://api.planet.com/>. Acesso em: 23 out. 2023.

PEDREGOSA, F. et al. Scikit-learn: Machine Learning in Python. Journal of Machine Learning Research, v. 12, n. 85, p. 2825-2830, 2011.

SOLARI, F.; SHANAHAN, J.F.; FERGUSON, R.B.; ADAMCHUCK, V. I. An active sensor algorithm for corn N applications based on a chlorophyll meter sufficiency index framework. **Agronomy Journal**, v.102, p.1090-1098, 2010.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. Remote Sensing of Environment, v. 8, p. 127-150, 1979.

DETECÇÃO DO ATAQUE DO BICUDO-DA-CANA (COLEOPTERA: CURCULIONIDAE) VIA SENSORIAMENTO REMOTO ORBITAL

João Rafael Silva Soares [1]; Gabriela Franchini [1]; Juliana Lívia Vieira [2]; Vinicius Cesarin [2]; Antonio Maria Garcia Tommaselli [3]; Nilton Nobuhiro Imai [3]; Odair Aparecido Fernandes [1]

[1] . Via de Acesso Prof. Paulo Donato Castellane s/n , 14884-900, Jaboticabal-SP, Brasil.. Departamento de Fitossanidade, Programa de Pós-Graduação em Agronomia - Entomologia Agrícola, Universidade Estadual Paulista (UNESP), Faculdade de Ciências Agrárias e Veterinárias.; [2] . Via de Acesso Prof. Paulo Donato Castellane s/n , 14884-900, Jaboticabal-SP, Brasil.. Centro de Pesquisa em Engenharia - Fitossanidade em cana-de-açúcar (CEPENFITO), Universidade Estadual Paulista (UNESP), Faculdade de Ciências Agrárias e Veterinárias; [3] . Rua Roberto Simonsen, 305 - Centro Educacional-P, 19060-900, Presidente Prudente-SP, Brasil. Departamento de Cartografia, Programa de Pós-Graduação em Ciências Cartográficas, Universidade Estadual Paulista (UNESP), Faculdade de Ciências Tecnológicas

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Os métodos tradicionais de monitoramento contínuo de pragas apresentam dificuldades para serem aplicados de forma eficaz na cultura da cana-de-açúcar. Como resultado, a frequência de amostragem adotada pelos produtores não é suficiente para permitir medidas de controle das pragas em tempo hábil, especialmente no caso do bicudo-da-cana, *Sphenophorus levis* Vaurie, 1978. A utilização de tecnologias como o sensoriamento remoto possibilita a obtenção de informações sobre o estado sanitário da lavoura sem a necessidade de contato físico, acelerando o processo de tomada de decisão. Neste estudo, modelos de aprendizado de máquina foram ajustados para entender o impacto do ataque do bicudo-da-cana por meio de características espectrais extraídas de sensores multiespectrais embarcados em satélites da constelação Planet®. Amostragens tradicionais do bicudo-da-cana foram realizadas mensalmente ao longo de cinco meses em três canaviais comerciais, avaliando três pontos aleatórios por parcela para contagem de colmos danificados, número total de colmos e quantidade de formas biológicas. Imagens capturadas do banco de dados da Planet® foram obtidas em intervalos próximos às amostragens. Após o processamento, foram calculadas informações derivadas das bandas espectrais, como índices de vegetação, componentes principais e atributos da matriz de co-ocorrência de nível de cinza. Os dados de cada parcela foram extraídos e combinados com os dados de campo para modelagem utilizando algoritmos de aprendizado de máquina. As árvores de decisão, representadas pelos algoritmos *Random Forest* e *Extreme Gradient Boosting Trees*, destacaram-se com maior poder preditivo. Os dados referentes ao primeiro e segundo meses de avaliação, quando as plantas apresentavam menor índice de área foliar (IAF), apresentaram os melhores resultados. Os resultados obtidos representam um primeiro passo importante para aprimorar o monitoramento em grande escala do bicudo-da-cana, aumentando a eficiência na tomada de decisão para o controle dessa praga-chave na cultura da cana-de-açúcar.

PALAVRAS-CHAVE: Aprendizagem de máquina; Manejo Integrado de Pragas de Precisão; Tomada de decisão

ABSTRACT

Traditional methods of continuous pest monitoring face challenges in being applied effectively to sugarcane crops. As a result, the sampling frequency adopted by growers may be insufficient to enable timely pest control measures, particularly in the case of the sugarcane billbug, *Sphenophorus levis* Vaurie, 1978. The use of technologies such as remote sensing allows for the acquisition of information about the crop's health status without the need for physical contact, thus speeding up the decision-making process. In this study, machine learning models were adjusted to understand the impact of sugarcane billbug attack through spectral characteristics extracted from multispectral

sensors mounted on satellites from Planet® constellation. Traditional sampling of the sugarcane billbug was conducted monthly over five months in three commercial sugarcane fields, evaluating three random points per plot for counting damaged stalks, total number of stalks, and the quantity of biological forms. Images extracted from Planet® database were obtained at intervals close to the sampling periods. Information derived from spectral bands, including vegetation indices, principal components, and gray-level co-occurrence matrix attributes, was extracted for each plot. These data were then combined with field observations to model using machine learning algorithms. Decision trees, represented by the Random Forest and Extreme Gradient Boosting Trees algorithms, stood out with greater predictive power. Data from the first and second months of evaluation, when the plants had a lower leaf area index (LAI), showed the best results. The findings represent an important first step in improving large-scale monitoring of the sugarcane billbug, enhancing the efficiency of decision-making for controlling this key pest in sugarcane.

KEYWORDS: Decision making; Machine learning; Precision Integrated Pest Management

INTRODUÇÃO

O monitoramento eficaz de pragas é uma etapa fundamental nos programas de Manejo Integrado de Pragas (MIP), pois permite a detecção e o controle precoce de infestações (Dara, 2019). Na cultura da cana-de-açúcar (*Saccharum spp.*), o processo de amostragem de pragas apresenta desafios significativos devido à dificuldade de realizar coletas frequentes e representativas, o que compromete a adoção de ações de controle em tempo hábil (Reagan e Mulcahy, 2019).

Um exemplo claro desse desafio é o monitoramento do bicudo-da-cana (*Sphenophorus levis* Vaurie, 1978), uma praga que danifica o rizoma e a base dos colmos da planta (Dinardo-Miranda, 2005). O método tradicional de amostragem, baseado na remoção manual das touceiras e abertura dos colmos para contagem de injúrias e formas biológicas do inseto (larvas, pupas e adultos), é extremamente trabalhoso e ineficaz em áreas extensas (Pavlu et al., 2016). Como resultado, esse procedimento tende a ser ignorado por grandes produtores, aumentando o risco de infestações severas do bicudo-da-cana.

Diante disso, o sensoriamento remoto surge como uma alternativa promissora para otimizar a detecção dos danos causados pelo bicudo-da-cana e aumentar a eficiência de seu monitoramento. A hipótese é que as injúrias causadas pela praga induzem alterações fisiológicas e estruturais na planta, visíveis por meio de sintomas visuais de ataque como o amarelecimento progressivo das plantas em reboleiras. Tais injúrias possivelmente afetariam a reflectância espectral, especialmente nas faixas do visível e infravermelho próximo e essas respostas podem ser capturadas por sensores multiespectrais (Zhang et al., 2019; Rhodes et al., 2022). A detecção dessas alterações via sensoriamento remoto pode fornecer um método mais ágil e preciso para orientar decisões de controle.

OBJETIVOS

Nosso objetivo foi avaliar a adequação do sensoriamento orbital multiespectral como ferramenta de monitoramento do bicudo-da-cana, além de identificar quais informações são relevantes para sua detecção para que possam ser aplicadas no monitoramento em larga escala desta praga.

MATERIAL E MÉTODOS

A pesquisa foi realizada em três canaviais comerciais localizados nos municípios de Barrinha e Itirapina, no estado de São Paulo, Brasil, abrangendo as safras de 2022/2023 e 2023/2024. Todas as práticas de manejo agronômico seguiram as recomendações técnicas, exceto para o controle do bicudo-da-cana. O experimento consistiu em 64 parcelas com uma área aproximada de 600 m² cada.

As amostragens foram realizadas mensalmente, avaliando-se três pontos aleatórios por parcela. A amostragem envolveu a retirada de touceiras em pontos selecionados aleatoriamente entre as fileiras, alternando a quantidade de pontos entre as linhas de plantio. Após a remoção dos rizomas nas trincheiras com o uso de um enxadão, os colmos foram cortados longitudinalmente com facão. Foi realizada uma inspeção cuidadosa para quantificar o número de colmos danificados, o número total de colmos e a quantidade de formas biológicas (larvas, pupas e adultos dentro da touceira). Com base nesses valores, foi calculada a proporção de tocos atacados (T.A.), dividindo-se o número de colmos atacados pelo número total de colmos.

Imagens orbitais dos nanossatélites da constelação PlanetScope® foram utilizadas para acompanhar os dados coletados em cada campo e nas datas de avaliação (3 campos, 5 meses, totalizando 15 imagens). A seleção das imagens seguiu os critérios de cobertura de nuvens inferior a 1% e a disponibilidade na data da amostragem. Caso esses critérios não fossem atendidos, selecionou-se a imagem mais próxima possível da data de amostragem, dentro de um intervalo de ± 5 dias. Em seguida, as imagens escolhidas foram recortadas conforme os limites do campo e harmonizadas radiometricamente, caso tivessem sido capturadas por mais de um satélite.

As imagens e camadas vetoriais foram trabalhadas no ArcGIS Pro®. As camadas vetoriais das parcelas foram criadas no ArcGIS a partir da composição RGB de alta resolução georreferenciadas de um VANT. Um buffer interno foi aplicado nos limites de cada parcela para excluir possíveis efeitos de bordadura e garantir que os dados espectrais correspondessem à parcela correspondente.

Em seguida, as imagens foram importadas no software R versão 4.2.1 (R Core Team, 2022). Entre os processamentos realizados foram a criação dos índices de vegetação e extração dos três primeiros componentes principais (PC's) e atributos de textura das imagens através da matriz de co-ocorrência de nível de cinza (GLCM). As informações geradas foram empilhadas separadamente para a composição de um hipercubo. A partir das informações empilhadas, foi calculada a média dos pixels em cada camada de informação (isto é, bandas, índices de vegetação e texturais, PC's) considerando-se a camada vetorial das parcelas. As informações extraídas foram combinadas com os dados observados em campo para modelagem via algoritmos de *machine learning*.

A proporção de tocos atacados foi convertida para área sob a curva de progresso da injúria (AUC) antes da modelagem (Ruppel, 1984). A abordagem para calcular a AUC leva em consideração a área trapezoidal entre a proporção de tocos atacados entre a amostragem no mês i e a próxima amostragem e a diferença em dias entre as amostragens para cada parcela j (Ruppel, 1984):

$$AUC_{i,j+1} = \left[\frac{r_{i,j} + r_{i,j+1}}{2}\right] * (T_{i,j+1} - T_{i,j}) \quad \text{Eq. (4)}$$

em que $r_{i,j}$ é a proporção de tocos atacados observado na parcela i, na amostragem j, $r_{i,j+1}$ é a proporção de tocos atacados observado na parcela i, da amostragem subsequente e $T_{i,j+1}$ - $T_{i,j}$ é a diferença em dias entre as duas amostragens sequenciais para a parcela i.

Após o cálculo da área para cada mês, as áreas são então somadas para a geração das curvas de progresso de ataque da praga (Ruppel, 1984):

$$AUC_{cumulativo} = \sum_{i,j+1} AUC_{i,j} + AUC_{i,j+1} \quad \text{Eq. (5)}$$

A fim de determinar qual momento na fenologia da cana-de-açúcar se obtém os melhores resultados, o conjunto de dados foi dividido considerando os dados cumulativos em sequência, ou seja, a AUC entre a primeiro mês de avaliação e segunda avaliação, primeira avaliação e terceira avaliação até incorporar as observações de todas as datas.

O ajuste dos modelos preditivos foi implementado utilizando o pacote "Tidymodels". Em cada subconjunto, os dados foram divididos aleatoriamente para treinamento e teste dos modelos considerando uma proporção de 80:20. Os dados do treinamento ainda foram subdivididos em conjuntos menores para estimar o erro de teste associado a um determinado modelo (avaliação do modelo) e selecionar o nível de flexibilidade adequado do modelo preditivo (seleção dos hiperparâmetros do modelo). O método de reamostragem empregado foi a validação cruzada k fold ("k fold cross validation"). Em nosso estudo, os dados de treinamento foram divididos em 10 partes iguais e repetido 5 vezes.

Foram testados cinco algoritmos para determinar qual deles retorna a melhor acurácia e precisão do progresso da intensidade de ataque da praga. Entre os algoritmos selecionados estão as árvores de decisão aleatórias ("Random Forest"), máquinas de suporte de vetor ("Suport Vector Machine") com kernels polinomial e radial, árvores de aumento de gradiente extremo ("XGBoost"), regressão lasso e a regressão dos mínimos quadrados parciais esparsa ("S-PLSR"). Os modelos foram treinados e comparados entre si para averiguar qual possui maior capacidade preditiva utilizando as métricas raíz do erro quadrático médio (RMSE) e coeficiente de determinação (R^2). Aquele modelo que conferiu menores valores de RMSE e maior valor de R^2 foi selecionado. A partir do modelo eleito, foram construídos gráficos de importância das variáveis para visualizar a força da relação entre cada atributo e a observação prevista pelo modelo.

RESULTADOS E DISCUSSÃO

Em todos os subconjuntos de dados, os algoritmos baseados em árvores de decisão sobressaíram sobre os demais (Tabela 1). O algoritimo XGBoost obteve melhores métricas para os subconjuntos AUC mês 1 + mês 2 e AUC mês 1 + mês 2 + mês 3 enquanto Random Forest venceu nos demais conjuntos de dados. Entre os subconjuntos e algoritmos testados nos dados de treinamento, aquele que proporcionou melhores métricas foram AUC mês 1 + mês 2, preditas pelo modelo XGBoost, seguidos por Random Forest, Regressão Lasso, SVM Polinomial e Radial e por fim, Regressão S-PLS.

Tabela 1. Métricas dos modelos a partir da reamostragem dos dados de treinamento. A linha em negrito destaca o dataset e modelo selecionado para avaliação nos dados de teste

Conjunto de dados	Algoritmo	RMSE	R^2
AUC mês 1 + mês 2	**XGBoost**	**1.68 ± 0.06**	**0.79 ± 0.01**
	Random Forest	1.69 ± 0.06	0.79 ± 0.01
	Regressão Lasso	1.70 ± 0.06	0.79 ± 0.01
	SVM Polinomial	1.72 ± 0.06	0.78 ± 0.01
	SVM Radial	1.80 ± 0.06	0.76 ± 0.01
	Regressão S-PLS	1.92 ± 0.06	0.73 ± 0.01
AUC mês 1 + mês 2 + mês 3	XGBoost	2.62 ± 0.07	0.74 ± 0.01
	Random Forest	2.65 ± 0.06	0.73 ± 0.01
	Regressão Lasso	2.66 ± 0.07	0.73 ± 0.01

	SVM Polinomial	2.67 ± 0.06	0.73 ± 0.01
	SVM Radial	2.69 ± 0.07	0.72 ± 0.01
	Regressão S-PLS	2.85 ± 0.07	0.69 ± 0.01
AUC mês 1 + mês 2+ mês 3+ mês 4	XGBoost	3.31 ± 0.07	0.70 ± 0.01
	Random Forest	3.25 ± 0.06	0.71 ± 0.01
	Regressão Lasso	3.33 ± 0.07	0.69 ± 0.01
	SVM Polinomial	3.37 ± 0.07	0.69 ± 0.01
	SVM Radial	3.40 ± 0.06	0.68 ± 0.01
	Regressão S-PLS	3.37 ± 0.06	0.69 ± 0.01
AUC mês 1 + mês 2 + mês 3+ mês 4 + mês 5	XGBoost	3.90 ± 0.06	0.69 ± 0.01
	Random Forest	3.89 ± 0.06	0.69 ± 0.01
	Regressão Lasso	4.07 ± 0.07	0.66 ± 0.01
	SVM Polinomial	4.13 ± 0.06	0.65 ± 0.01
	SVM Radial	4.11 ± 0.06	0.65 ± 0.01
	Regressão S-PLS	4.17 ± 0.07	0.64 ± 0.01

Baseado no subconjunto de dados e modelo vencedor com hiperparâmetros ajustados, o algoritmo XGBoost (Tabela 2) obteve um RMSE de 1.68 e R2 de 0.80 nos dados de teste.

Tabela 2. Configuração de hiperparâmetros e métricas do modelo XGBoost selecionado nos dados de teste

Nº de árvores (trees)	Profundidade da árvore (tree_depth)	Preditores selecionados aleatoriamente (mtry)	Taxa de aprendizado (learning_rate)	Tamanho mínimo do nó (min_n)	Redução Mínima de Perdas (loss_reduction)	Proporção de amostradas observadas (sample_size)	RMSE	R^2
500	2	254	0.00690	26	0.00000000214	0.613	1.68	0.80

O modelo XGBoost teve uma tendência de subestimação para valores de AUC maiores (**Figura 1-A**). As variáveis preditoras que tiveram maiores pesos no modelo envolveram variáveis preditores de todas as classes do conjunto de dados, isto é, reflectância de bandas (3), índices de vegetação (4), PC's (1) e atributos de textura (2) (**Figura 1-B**). As variáveis que tiveram maior peso foram a banda "Red" e o índice de vegetação MCARI. As demais variáveis tiveram contribuições consideravelmente em menor grau.

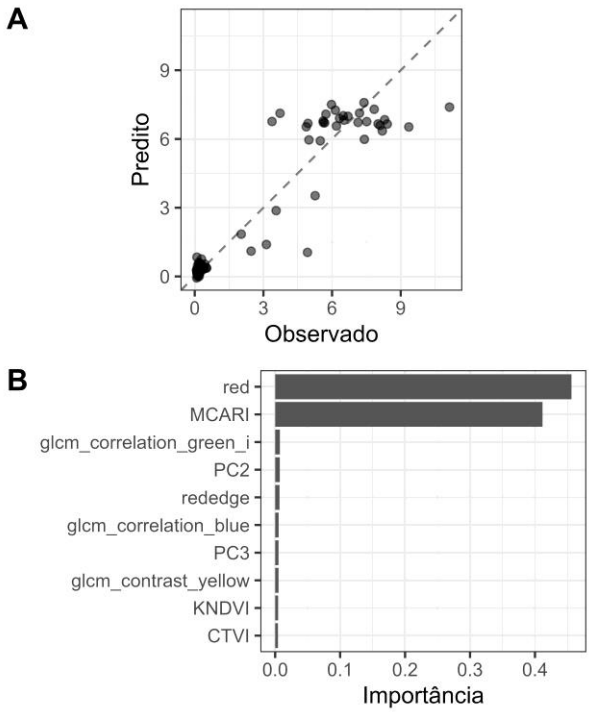


Figura 1 - Valores preditos vs observados (A) e importância de variáveis em projeção (VIP) (B) pelo modelo XGBoost nos dados de teste.

Entre as variáveis mais importantes destacadas pelo gráfico VIP estão o índice de vegetação MCARI e a banda "Red". A injúria do bicudo-da-cana no rizoma pode comprometer a capacidade da planta de absorver água, levando ao estresse hídrico. Em consequência, a clorofila, que absorve fortemente na região azul e vermelha do espectro, pode ser degradada ou reduzida em plantas infestadas por pragas e resultar em maior reflexão de energia da região do vermelho. O MCARI fornece uma medida da profundidade da absorção de clorofila e é sensível a variações em sua concentração, bem como a variações no índice de área foliar (IAF) (Daughtry *et al.*, 2000). Seus valores são menos afetados pelas condições de iluminação, pela refletância de fundo do solo e de outros materiais não fotossintéticos observados (Daughtry *et al.*, 2000). Isso é importante, pois em canaviais em fase de rebrote inicial, conforme incorporado no conjunto de dados vencedor, ainda é visível uma grande deposição de palha sobre o solo. Por outro lado, assim como a banda azul, a banda do vermelho está relacionada com a quantidade de energia que a planta absorve em seus fotossistemas. Consequentemente, quanto mais a planta está estressada, mais energia da banda vermelha ela refletirá. Ambos preditores possuem sentido biológico, uma vez que plantas atacadas pelo bicudo-da-cana amarelecem as folhas mais velhas. Em plantas jovens, o ataque da praga é mais prejudicial, pois pode levar a mortalidade de perfilhos da touceira e consequentemente redução de estande, o que impactará a área foliar.

CONCLUSÃO

Informações derivadas da constelação Planet® e aplicadas em modelos de *machine learning* tiveram predições satisfatórias e evidenciaram ser uma ferramenta promissora para o monitoramento de *S. levis*. Entre as variáveis de maior importância destacam-se a banda "Red" e o indíce de vegetação MCARI. Satélites oferecem maior cobertura terrestre do que outras tecnologias de detecção remota, o que pode aumentar a eficiência de monitoramento regional do bicudo-da-cana. Dessa forma, áreas possivelmente atacadas por *S. levis* e detectadas pelas imagens podem identificar "hot spots" e direcionar uma equipe de amostradores em campo para confirmação da causa da anomalia pelas imagens. Tais resultados representam um primeiro passo para o aprimoramento do monitoramento em grande escala do bicudo-da-cana.

AGRADECIMENTOS

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) - Código Financiamento - 001 pelo apoio financeiro e à Usina São Martinho pela disponibilidade de área e colaboradores para a condução dos experimentos. João Rafael Silva Soares foi bolsista FAPESP (FAPESP 2021/09645-0). Este trabalho é uma contribuição associada ao Centro de Pesquisa em Engenharia - Fitossanidade em cana-de-açúcar (CEPENFITO) (FAPESP 2017/25258-1).

REFERÊNCIAS

DARA, S. K. The new Integrated Pest Management paradigm for the modern age. **Journal of Integrated Pest Management**, v. 10, n. 1, 2019.

DAUGHTRY, C. S. T.; WALTHALL, C. L.; KIM, M. S.; COLSTOUN, E. B.; MCMURTREY III, J. E. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. **Remote Sensing of Environment**, v. 74, n. 2, p. 229-239, 2000.

DINARDO-MIRANDA, L. L. Nematóides e pragas de solo em cana-de-açúcar. **Informações agronômicas nº 110**, v. 1, p. 25-32, 2005.

PAVLU, F. A.; MOLIN, J. P.; PAVLU, F. A.; MOLIN, J. P. A sampling plan and spatial distribution for site-specific control of *Sphenophorus levis* in sugarcane. **Acta Scientiarum. Agronomy**, v. 38, n. 3, p. 279, 2016.

R CORE TEAM. **R: a language and environment for statistical computing**. Disponível em: <https://www.R-project.org/>.

REAGAN, T. E.; MULCAHY, M. M. Interaction of cultural, biological, and varietal controls for management of stalk borers in Louisiana sugarcane. **Insects**, v. 10, n. 9, p. 305, 2019.

RHODES, M. W.; BENNIE, J. J.; SPALDING, A.; FFRENCH-CONSTANT, R. H.; MACLEAN, I. M. D. Recent advances in the remote sensing of insects. **Biological Reviews**, v. 97, n. 1, p. 343-360, 2022.

RUPPEL, R. F. Model for effective timing of an insecticide. **Journal of Economic Entomology**, v. 77, n. 5, p. 1083-1085, 1984.

ZHANG, J.; HUANG, Y.; PU, R.; GONZALEZ-MORENO, P.; YUAN, L.; WU, K.; HUANG, W. Monitoring plant diseases and pests through remote sensing technology: a review. **Computers and Electronics in Agriculture**, v. 165, p. 104943, 2019.

ÍNDICES DE VEGETAÇÃO COMO MÉTODOS DE DETECÇÃO E PREDIÇÃO DE DANOS PARA FERRUGEM DA FOLHA NA CULTURA DO TRIGO

YURI GUERREIRO RAMOS [1]; MARCELO GIOVANETTI CANTERI [2]; JORGE BENIGNO [3]
[1]Eng. Agrônomo, Doutorando. Londrina - PR, Fone: (043) 98800.0999, yuri.guerreiro@uel.br. Universidade Estadual de Londrina, UEL; [2]Eng. Agrônomo, Professor, Doutor. Londrina - PR. Universidade Estadual de Londrina, UEL; [3]Eng. Agrônomo. Londrina - PR. Alvaz Agritech

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
Sistemas de detecção e quantificação de doenças podem se basear em medidas de refletância e índices de vegetação. Neste contexto, objetivou-se verificar o potencial uso de índices de vegetação como métodos de detecção e predição de danos para ferrugem da folha na cultura do trigo. Foi instalado um experimento na Fazenda Escola da Universidade Estadual de Londrina (UEL), no município de Londrina, PR no ano de 2022 com a cultivar de trigo TBIO Ponteiro. O delineamento experimental utilizado foi em blocos ao acaso com oito tratamentos e quatro repetições. Os tratamentos consistiram na aplicação do fungicida Protioconazol + Trifloxistrobina + Bixafen em diferentes estádios fenológicos da cultura. A utilização do fungicida em diferentes épocas nos tratamentos tem como objetivo gerar um gradiente de severidade entre as parcelas. As avaliações foram realizadas com um sensor Micasense-MX acoplado à um drone DJI Inspire 2, obtendo os índices de vegetação NDVI, NQAB, NQAF, NDRE, VARI e NIR, também sendo calculadas as áreas abaixo da curva de progresso (AACP) dos índices. As melhores equações geradas para estimar a severidade da doença obtiveram R^2 de 63,35 a 65 %, referentes às AACP dos índices NQAB, VARI e NIR. As equações geradas para estimar os danos obtiveram R^2 de 64 a 70 %.

PALAVRAS-CHAVE: sensoriamento remoto; vant; reflectância

ABSTRACT
Disease detection and quantification systems can be based on reflectance measurements and vegetation indices. In this context, the objective was to verify the potential use of vegetation indices as methods of detecting and predicting damage to leaf rust in wheat. One experiment was installed at the School Farm of the State University of Londrina (UEL), in the city of Londrina, PR in 2022 with the wheat cultivar TBIO Ponteiro. The experimental design used was randomized blocks with eight treatments and four replications. The treatments consisted of applying the fungicide Prothioconazole + Trifloxystrobin + Bixafen at different phenological stages of the crop. The use of fungicide at different timming in treatments aims to generate a severity gradient between plots. The evaluations were carried out with a Micasense-MX sensor coupled to a DJI Inspire 2 drone, obtaining the NDVI, NQAB, NQAF, NDRE, VARI and NIR vegetation indices, also calculating the areas under the progress curve (AACP) of the indices. The best equations to estimate severity obtained R^2 of 63.35 to 65%, referring to the AACP of NQAB, VARI and NIR. The equations to estimate damage obtained R^2 of 64 to 70%.

KEYWORDS: ;

INTRODUÇÃO

Perdas acarretadas por doenças na cultura do trigo podem ser superiores à 50 %, reduzindo a área fotossintética e aumentando a respiração (EMBRAPA, 2006). No trigo, as doenças mais importantes

são o oídio, as ferrugens, assim como o complexo das manchas foliares e a giberela (FERNANDES; PICININI, 1999).

A quantificação de doenças é uma etapa crucial para estudos epidemiológicos e para avaliação de estratégias de controle e, para que erros sejam minimizados, o método utilizado na quantificação deve fornecer resultados acurados e precisos. Os tecidos sadios refletem o infravermelho com maior intensidade do que os tecidos doentes (CANTERI, 1998). Sendo assim, sistemas de detecção e quantificação de doenças podem se basear em medidas do espectro em diferentes comprimentos de onda (WEST et al., 2003). Filmes coloridos infravermelhos e, mais recentemente, câmeras digitais capazes de captar diferentes comprimentos de onda podem ser utilizados na avaliação de doenças por permitirem a distinção entre tecidos sadios e sintomáticos (BERGAMIN FILHO, 2018). Os índices de vegetação foram concebidos para otimizar a interpretação dos dados de refletância.

Segundo Sugiura et al. (2016, apud BERGAMIN FILHO, 2018), a utilização de sensores de radiação em veículos aéreos não tripulados (VANT), drones, deverá ampliar o uso dessa tecnologia na detecção e na quantificação de doenças de plantas.

OBJETIVOS

Esse trabalho teve como objetivo verificar o potencial uso de índices de vegetação como métodos de detecção e predição de danos para doenças na cultura do trigo.

MATERIAL E MÉTODOS

Foi instalado um experimento na Fazenda Escola da Universidade Estadual de Londrina (UEL), localizada nas coordenadas: Latitude de - 23,341690, longitude de - 51,2116956 e altitude 564 m, no município de Londrina, PR no ano de 2022 com a cultivar de trigo TBIO Ponteiro. Os detalhes em relação à instalação do experimento estão descritos na Tabela 1.

Tabela 1 - Cultura, cultivar, data de semeadura, data da aplicação e estádio de desenvolvimento, Londrina - PR.

Cultura	**Cultivar**	**Data de semeadura**	**Data da aplicação**			
			2.9[a]	**3.5[a]**	**4.5[a]**	**5.0[a]**
Trigo	TBIO Ponteiro	27/04/2022	15/06/2022	06/07/2022	28/07/2022	18/08/2022

[a]Estádios de desenvolvimento: 2.9, perfilhamento completo; 3.5, quinto nó visível na elongação; 4.5, emborrachamento completo; 5.0, início do espigamento (ZADOKS et al., 1974).

Em relação aos tratamentos, foi utilizado o fungicida protioconazol + trifloxistrobina + bixafen (175 + 150 + 125 g i.a. L^{-1}), aplicado na dose de produto comercial de 500 $mL.ha^{-1}$ em diferentes estádios fenológicos da cultura (Tabela 2). A utilização do fungicida em diferentes épocas nos tratamentos tem como objetivo gerar um gradiente de severidade entre as parcelas, propiciando a diferenciação das mesmas para posterior detecção da severidade pelos índices de vegetação e predição dos danos.

Tabela 2 - Tratamentos, estádios de desenvolvimento e número de aplicações do fungicida para controle de doenças fúngicas na cultura do trigo, Londrina - PR.

Tratamentos	**ED[a]**	**Nº de aplicações**

T1	-	-
T2	2.9, 3.4, 4.5, 5.0	4
T3	2.9, 3.4, 4.5	3
T4	2.9, 3.4	2
T5	2.9	1
T6	3.4, 4.5, 5.0	3
T7	4.5, 5.0	2
T8	5.0	1

[a]Estádios de desenvolvimento: 2.9, perfilhamento completo; 3.5, quinto nó visível na elongação; 4.5, emborrachamento completo; 5.0, início do espigamento (ZADOKS et al., 1974).

As avaliações foram realizadas com um sensor Micasense-MX acoplado à um VANT DJI Inspire 2. A resolução do sensor foi de 1280 x 960 (1.2 MP por banda EO), as bandas espectrais foram azul, verde, vermelho, limite do vermelho e infravermelho próximo (IVP). Os voos para obtenção dos índices de vegetação, foram realizados juntamente à cada avaliação de severidade ferrugem da folha para a cultura do trigo, durante o ciclo da cultura (Tabela 3).

Tabela 3 - Data da captura com sensor e estádio de desenvolvimento, Londrina - PR.

Data da captura com sensor		
4.3[a]	**4.5[a]**	**4.5[a]**
21/07/2022	29/07/2022	05/08/2022

[a]Estádios de desenvolvimento na avaliação: 4.3, início do emborrachamento; 4.5, emborrachamento completo (ZADOKS et al., 1974).

Com os dados dos índices de vegetação e NIR, foram calculadas as áreas abaixo da curva de progresso do NDVI, NDRE, NQAB, NQAF, VARI, NIR por integração trapezoidal (SHANER; FINNEY, 1987). Para este cálculo foi utilizado o programa estatístico Scout, baseado na arquitetura ARM (Advanced Risk Machine) (SÉQUIN; PATTERSON, 1982).

Os dados foram submetidos à análise de variância pelo teste de F e as diferenças entre as médias, quando significativas, foram comparadas pelo teste de Scott Knott, ao nível de 5 % de probabilidade, utilizando-se o programa SASM-Agri (CANTERI et al., 2001).

Todas as relações foram analisadas por regressão linear, utilizando-se o programa Microsoft Office Excel®

RESULTADOS E DISCUSSÃO

Para todas as áreas abaixo da curva de progresso dos índices, duas a quatro aplicações iniciando no perfilhamento ou então três aplicações iniciando na elongação, diferiram estatisticamente dos demais tratamentos e testemunha (Tabela 4).

Em trabalho conduzido por Dehkordi et al. (2020), resultados mostraram que imagens RGB baseadas em UAV capturaram as alterações nos espectros de reflectância típicos das folhas de trigo entre os canais espectrais verde e vermelho que resultaram de infecções por patógenos biotróficos que causam a ferrugem da folha e ferrugem linear do trigo.

Tabela 4 - Área abaixo da curva de progresso do NDVI, NQAB, NQAF, NDRE, VARI, NIR (AACP NDVI, AACP NQAF, AACP NDRE, AACP VARI, AACP NIR) nos tratamentos com diferentes épocas e números de aplicações de fungicida, na cultura do trigo (*Triticum aestivum* L.), cultivar TBIO PONTEIRO, safra 2022, Londrina - PR.

Tratamentos[a]	**Índices de vegetação***					
	AACP NDVI	**AACP NQAB**	**AACP NQAF**	**AACP NDRE**	**AACP VARI**	**AACP NIR**
1-Testemunha	11,97088 a	60,46032 a	46,45884 a	7,473917 a	5,487873 a	165070,2 a
2-Perf./ Elong./ Embor./ Espig.	12,82558 b	62,7322 b	47,50367 b	8,447997 b	7,499876 b	182045,4 b
3-Perf./ Elong./ Embor.	12,81595 b	62,76048 b	47,49658 b	8,442178 b	7,495543 b	182562,1 b
4-Perf./ Elong.	12,76468 b	62,47911 b	47,42383 b	8,374307 b	7,515019 b	179491,7 b
5-Perf.	12,27081 a	61,44096 a	46,81249 a	7,797338 a	6,294004 a	174374,7 a
6-Elong./ Embor./ Espig.	12,73551 b	62,35811 b	47,42226 b	8,380635 b	7,178614 b	179155,5 b
7-Embor./ Espig.	12,224 a	61,18405 a	46,71388 a	7,691669 a	6,197416 a	171228 a
8-Espig.	12,09132 a	60,75353 a	46,53804 a	7,526342 a	5,870878 a	168048,1 a
C.V. (%)	1,58	0,87	0,48	2,62	7,34	2,77

[a]Estádios de desenvolvimento na aplicação: 2.9, perfilhamento completo; 3.5, quinto nó visível na elongação; 4.5, emborrachamento completo; 5.0, início do espigamento (ZADOKS et al., 1974).

*Médias seguidas de mesma letra não diferem estatisticamente entre si pelo teste de Scott knott (P<0,05).

As melhores equações geradas para estimar a severidade da doença obtiveram R^2 de 63,35 a 65 %, referentes às AACP dos índices NQAB, VARI e NIR. As melhores equações geradas para estimar os danos obtiveram R^2 de 64 a 70 % (Tabela 5). Em trabalho conduzido por Rissini (2015), o NDVI obtido por diferentes sensores apresentou relação direta com a produtividade, possibilitando a elaboração de modelos de estimativa de produtividade desde o início de desenvolvimento da cultura.

Tabela 5 - Equações de função de dano, função de severidade e coeficientes de determinação para a AACP dos índices de vegetação, na cultura do trigo (*Triticum aestivum* L.), cultivar TBIO PONTEIRO, safra 2022, Londrina - PR.

	Equação de função de dano, função de severidade e coeficiente de determinação						
	AACP NDVI	**AACP NQAB**	**AACP NQAF**	**AACP NDRE**	**AACP VARI**	**AACP NIR**	
AACPD ferrugem da folha do trigo	y = -0,0008x + 12,961 R^2 = 0,5763	y = -0,0023x + 63,122 R^2 = 0,6358	y = -0,0011x + 47,678 R^2 = 0,5662	y = -0,001x + 8,6144 R^2 = 0,5629	y = -0,002x + 7,8954 R^2 = 0,6335	y = -16,569x + 185027 R^2 = 0,65	

Produtividade	y = 807,12x - 8232,9 R² = 0,6618	y = 322,43x - 18091 R² = 0,7022	y = 630,92x - 27857 R² = 0,6612	y = 664,61x - 3502,3 R² = 0,6594	y = 346,85x - 495,52 R² = 0,6467	y = 0,0447x - 6006,5 R² = 0,6917	

CONCLUSÃO

As melhores equações geradas para estimar a severidade da doença obtiveram R² de 63,35 a 65 %, referentes às AACP dos índices NQAB, VARI e NIR. As equações geradas para estimar os danos obtiveram R² de 64 a 70 %. As variações observadas indicam a necessidade da continuidade desta linha de pesquisa em diferentes locais e anos, utilizando cultivares com reações semelhantes às doenças foliares deste trabalho, auxiliando a tomada de decisão em relação ao momento de intervenção com fungicidas para controle de doenças foliares em trigo.

REFERÊNCIAS

BERGAMIM FILHO, A.; AMORIM, L.; REZENDE, J. A. M. **Manual de Fitopatologia:** Princípios e conceitos. 5 ed. São Paulo: Agronômica Ceres, 2018, Vol. 1.

BOLLER W.B; FORCELINI, C.A.; HOFFMANN L.L.; CASA R.T. Tecnologia de aplicação de fungicidas - parte II. **Revisão anual de patologia de plantas**.16:85-132, 2008.

BUCK J.W.; WISE K.; DONG, W. Effect of postsymptom application of fungicides on urediniospore production by *Puccinia triticina* on wheat and *P. hemerocallidis* on daylily. **The American Phytopathological Society**. 95:3:325-330, 2011.

CANTERI, M. G. **Uso de medidas da área foliar sadia e refletância no manejo da mancha angular do feijoeiro**. 1998. 81 p. Tese. (Doutorado em Agronomia - Escola Superior de Agricultura "Luiz de Queiroz", da Universidade de São Paulo, SP.

COOK, R.J.; HIMS, M.J.; VAUGHANB T.B. Effects of fungicide spray timing on winter wheat disease control. **Plant Pathology**. 48:1:33-50, 1999.

DEHKORDI, R. H.; JARROUDI, M. E.; KOUADIO, L.; MEERSMANS, J.; BEYER, M. Monitoring Wheat Leaf Rust and Stripe Rust in Winter Wheat Using High-Resolution UAV-Based Red-Green-Blue Imagery. **Remote Sensing,** v. 12, n. 3696, p. 1-18, 2020.

EMBRAPA. Ferrugem da folha - Documentos Online Nº 64. 2006. **Agência Embrapa de Informação Tecnológica**. Disponível em: <http://www.cnpt.embrapa.br/biblio/do/p_do64_2.htm>. Acesso em: 01 de agosto de 2023.

FERNANDES, J. M. C; PICININI, E. C. Controlando as doenças de trigo na hora certa. Passo Fundo: Embrapa Trigo, 1999. 3p.html. (Embrapa Trigo. Comunicado Técnico Online, 22). Disponível: http://www.cnpt.embrapa.br/biblio/p_co22.htm. Acesso em: 16 de Junho de 2021.

OLIVEIRA G.M.; PEREIRA, D.D.; CAMARGO L,C.; BALAN, M.G.; CANTERI, M.G.; IGARASHI, S.; ABI SAAB, O. J. G. Controle da ferrugem da folha do trigo (*Puccinia triticina*) em diferentes momentos de aplicação de fungicida. **Arquivo do Instituto Biologico de São Paulo.** 8:4:436-441, 2013.

RISSINI, A. L. L.; KAWAKAMI, J.; GENÚ, A. M. Índice de vegetação por diferença normalizada e produtividade de cultivares de trigo submetidas a doses de nitrogênio. **Revista Brasileira de Ciência do Solo**, v. 39, p. 1703-1713, 2015.

SÉQUIN, C. H; PATTERSON, D. A. Design and implementation of RISC I. Computer Science Division. **Electrical Engineering and Computer Sciences**. 1982. 25 p.

SHANER, G.; FINNEY, R. F. The effects of nitrogen fertilization on the expression of show-midwing in knox what. **Phytopathology**, v. 67, p. 1051-1055, 1987.

WEST, J.S.; BRAVO, C.; OBERTI, R.; LEMAIRE, D.; MOSHOU, D.; MCCARTNEY, H.A. The potential of optical canopy measurements for targeted control of field crop diseases. **Annual Review Phytopathology**, v. 41, p. 593-614, 2003.

SENSORIAMENTO REMOTO AÉREO E INTELIGÊNCIA ARTIFICIAL PARA A CLASSIFICAÇÃO DE PLANTAS DANINHAS EM SILVICULTURA

Samuel de Assis Silva [1]; Amanda Teixeira Moreira Capacia [3]; Caique Carvalho Medauar [2]
[1]Docente. Alto Universitário, Guararema, Alegre, ES, 29500-000. Universidade Federal do Espírito Santo; [2]Especialista Global em Serviços Técnicos. Rua Domingos Jorge, 1.100 Cep 04779-900 - São Paulo - SP - Brasil. Envu - Environmental Science do Brasil Limitada; [3]Mestranda. Alto Universitário, Guararema, Alegre, ES, 29500-000. Universidade Federal do Espírito Santo

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
Com o presente trabalho se objetivou utilizar técnicas de sensoriamento remoto e machine learning para automatizar a identificação e classificação da incidência de plantas daninhas em áreas cultivadas com eucalipto, separando-as de acordo com a morfologia das folhas. O estudo foi desenvolvido em uma área de produção de eucalipto implantado no espaçamento de 3x2m. As avaliações da incidência de plantas daninhas foram realizadas in loco e a partir do sensoriamento remoto aéreo. Os aerolevantamentos foram realizados com sensor RGB e multiespectral embarcados em aeronave remotamente pilotada. A classificação das plantas daninhas foi realizada em ambiente python e a partir das imagens RGB e multiespectrais, utilizando os algoritmos SVM, Random Forest, k-NN e Decision Trees. O desempenho dos algoritmos foi avaliado a partir de diversas métricas calculadas a partir da matriz de confusão. Os melhores resultados foram observados quando do uso das imagens multiespectrais, entretanto, os resultados com as RGB foram satisfatórios, indicando a possibilidade de uso desses sensores no estudo da incidência de plantas daninhas. Os algoritmos Decision Trees e, principalmente, o k-NN apresentaram melhor desempenho para classificação de plantas daninhas e separação destas de acordo com a morfologia das folhas.

PALAVRAS-CHAVE: Aprendizado de máquinas; eucalipto; silvicultura de precisão

ABSTRACT
The present work aimed to use remote sensing and machine learning techniques to automate the identification and classification of the incidence of weeds in areas cultivated with eucalyptus, separating them according to the morphology of the leaves. The study was carried out in a eucalyptus production area located at a spacing of 3x2m. Weed incidence assessments were carried out in situ and using aerial remote sensing. The aerial surveys were carried out with an RGB and multispectral sensor on board a remotely piloted aircraft. The classification of weeds was carried out in a Python environment and based on RGB and multispectral images, using the SVM, Random Forest, k-NN and Decision Trees algorithms. The performance of the algorithms was evaluated based on several metrics calculated from the confusion matrix. The best results were observed when using multispectral images, however, the results with RGB were satisfactory, indicating the possibility of using these sensors in studying the incidence of weeds. Decision Trees algorithms and, mainly, k-NN showed better performance for classifying weeds and separating them according to leaf morphology.

KEYWORDS: Machine learning; eucalyptus; precision forestry

INTRODUÇÃO

No contexto da produção agrícola, as plantas daninhas representam um dos principais fatores de perda (Gharde et al., 2013). Quando presentes, competem vigorosamente por recursos essenciais, como água, luz, espaço e nutrientes, devido à sua resistência natural. Além disso, funcionam como

hospedeiras alternativas para pragas e doenças (Ghanizadeh e Harrington, 2019). Portanto, as plantas daninhas impactam negativamente a produtividade e a qualidade das colheitas, resultando em um aumento significativo nos custos de produção.

Para melhorar a eficácia das estratégias de controle de plantas daninhas, é essencial que se tenha um entendimento abrangente do nível de infestação e das espécies presentes nas áreas de produção (Gharde et al., 2018). Neste sentido, o sensoriamento remoto (SR), por sua eficiência no monitoramento de cultivos (Hunter et al., 2020) é uma ferramenta importante para mapear as plantas daninhas presentes nos talhões de produção florestal. Com as altas resoluções de sensores embarcados em aeronaves remotamente pilotadas (ARP), as avaliações utilizando o SR permitem resultado mais abrangentes e, no caso das plantas daninhas, descrevem com boa precisão distribuição da infestação auxiliando as intervenções no manejo.

O uso conjunto do SR e da inteligência computacional (IA) possibilita aprimorar de forma substancial a habilidade de identificar e classificar os elementos em análise. Com os algoritmos de aprendizado de máquinas tem-se evidenciado um notável aumento de desempenho na gestão operacional silvicultural, permitindo a identificação, medição e análise de grandes volumes de dados (Lan et al., 2021).

OBJETIVOS

Com o presente trabalho se objetivou utilizar técnicas de sensoriamento remoto e machine learning para automatizar a identificação e classificação da incidência de plantas daninhas em áreas cultivadas com eucalipto, separando-as de acordo com a morfologia das folhas.

MATERIAL E MÉTODOS

O estudo foi desenvolvido em uma área de produção de eucalipto, localizada na região norte do estado do Espírito Santo, sob as coordenadas médias de 18º 34' 36" S e 39º 51' 16" W e altitude média de 48m. O povoamento foi implantado em setembro de 2022, no espaçamento de 3x2m. Na Figura 1 é apresentada uma imagem aérea da lavoura, com ampliação, em detalhe, das entrelinhas. A área escolhida apresentava 125 dias após a implantação, no momento do aerolevantamento.

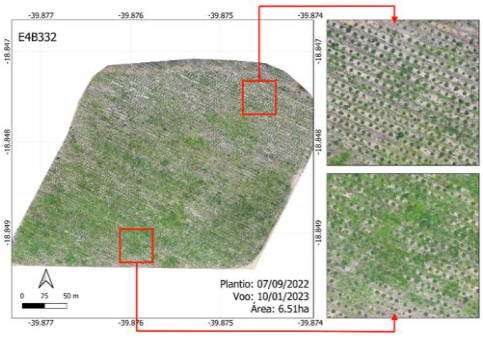


Figura 1. Imagem aérea da área de produção de eucalipto objeto deste estudo.

O estudo envolveu avaliações remotas e determinações in loco. As avaliações, in loco, consistiram na classificação visual e marcação, em campo, de amostras fotointerpretáveis de plantas daninhas. No aerolevantamento utilizou-se: a) sensor ótico RGB CMOS (original do DJI Phantom 4 Pro) que captura segmentos dos comprimentos de onda do espectro eletromagnético do visível - vermelho (R); verde (G), e; azul (B), e; b) sensor multiespectral RedEdge MX que captura segmentos dos comprimentos de onda do espectro eletromagnético do visível, do RedEdge e do infravermelho próximo (NIR).

Os sensores foram embarcados em aeronaves remotamente pilotadas do tipo asa rotativa (multirotor). Os aerolevantamentos foram realizados sempre às 12h, a uma altura de 120m, com velocidade de deslocamento variando de 9 a 12 $m.s^{-1}$ e sobreposições frontais e laterais de 80%, com GSD de 5 cm para o sensor RGB CMOS e 8 cm para a RedEdge MX. Após a obtenção das imagens, estas foram processadas para construção dos ortomosaicos utilizando o software livre OpenDroneMap (Drone Mapping Software). Os ortomosaicos foram exportados em formato GeoTiff para posterior análise em ambiente de programação. A teledetecção das plantas daninhas foi realizada a partir da resposta espectral do dossel, utilizando modelos de machine learning: a) random forest - RF, b) máquina de vetores de suporte - SVM (support vector machine); c) decision trees - DT, e; d) k-nearest neighbors - k-NN. Nas imagens aéreas foram selecionadas amostras de treinamento e amostras de teste para os modelos de machine learning, respeitando uma proporção de 3:1.

O desempenho da classificação foi avaliado por métricas calculadas a partir dos resultados da matriz de confusão gerada na classificação. Utilizou-se as métricas: a) acurácia; b) precisão; c) recall, e; d) f-score. A classificação foi realizada em duas etapas independentes, sendo a primeira para a classificação das plantas daninhas e definição dos níveis de infestação e a segunda para, utilizando o(s) melhor(es) modelo(s) da etapa anterior - separar as plantas daninhas de acordo com a morfologia das folhas - folha larga e folha estreita. Após as classificações, foram quantificados os percentuais da área ocupados por plantas daninhas, seguindo os resultados obtidos na primeira e na segunda etapa.

RESULTADOS E DISCUSSÃO

Os resultados da classificação geral das plantas daninhas são apresentados na Figura 2. A quantidade de plantas daninhas era elevada, porém com maior concentração nos terços inferior e médio do campo (sentido sul-norte). Em relação à análise visual, para todos os classificadores, é possível observar um maior quantitativo de plantas daninhas a partir da imagem multiespectral.

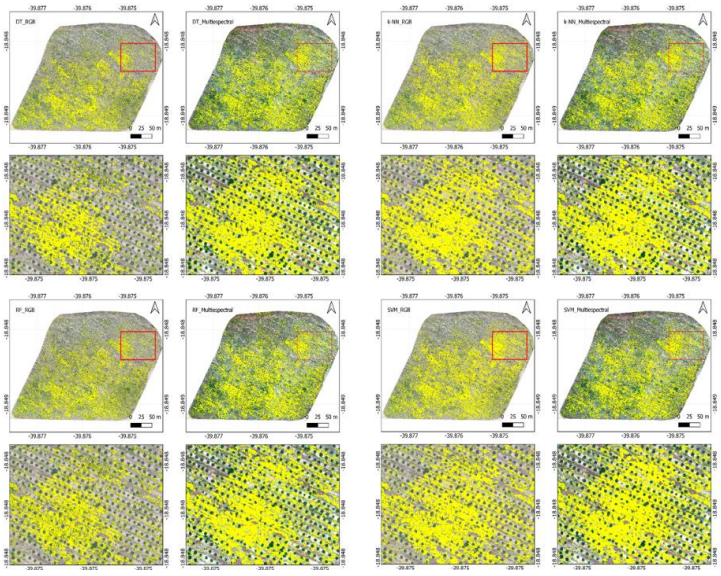


Figura 2. Classificação das plantas daninhas utilizando decision trees (DT), k-nearest neighbors (k-NN), Random forest (RF) e máquina de vetores de suporte (SVM) imagens RGB e multiespectrais.

Para as métricas (Tabela 1), os resultados foram muito semelhantes para todas as combinações (classificador x tipo de imagem). Os piores resultados foram observados para o RF, apesar de uma pequena diferença em relação aos demais, sendo inclusive superior para o recall do RF na imagem multiespectral. Os valores da maioria das métricas foram superiores a 0,80. Castro et al. (2018) comentam que, para sistemas complexos e imagens de alta resolução especial, valores superiores a 0,60 para as métricas utilizadas nesta pesquisa são considerados satisfatórios.

TABELA 1. Métricas da classificação das plantas daninhas, por classificador, utilizando os produtos dos sensores RGB e multiespectral.

Classificador	Precisão		Recall		f-score	
	Multiespectral	RGB	Multiespectral	RGB	Multiespectral	RGB
DT	0,86	0,85	0,88	0,73	0,87	0,78
k-NN	0,90	0,84	0,89	0,79	0,90	0,81
RF	0,79	0,81	0,89	0,66	0,84	0,73
SVM	0,88	0,79	0,87	0,70	0,88	0,75

DT - decision trees; k-NN - k-nearest neighbors; RF - random forest; SVM - máquina de vetores de suporte

A semelhança para os modelos e imagens se repete no percentual de cobertura das áreas pelas daninhas (Tabela 2). Com exceção do RF, os valores foram próximos para todas as métricas e imagens. Para o RF os valores foram diferentes quando comparados entre os classificadores e, principalmente, entre as imagens. Fletcher (2016) também aplicou o RF para classificar plantas daninhas em áreas de cultivo de soja e obteve resultados semelhantes aos deste estudo.

TABELA 2. Percentual de cobertura de área pelas plantas daninhas conforme estimativa a partir da classificação por diferentes algoritmos para distintos produtos de sensoriamento remoto aéreo.

Classificador	Área (%)	
	RGB	Multiespectral
DT	30,73	39,97
k-NN	37,07	37,18
RF	33,53	46,77
SVM	36,20	38,64

DT - decision trees; k-NN - k-nearest neighbors; RF - random forest; SVM - máquina de vetores de suporte

Para a separação das plantas daninhas em folhas larga e estreita, os resultados são apresentados na Figura 3. Observa-se a predominância de plantas de folha estreita, resultados compatíveis com as avaliações de campo. O SVM foi o algoritmo que mais superestimou o quantitativo de folhas largas, enquanto para os demais o comportamento das plantas e a quantidade aparentemente é semelhante.

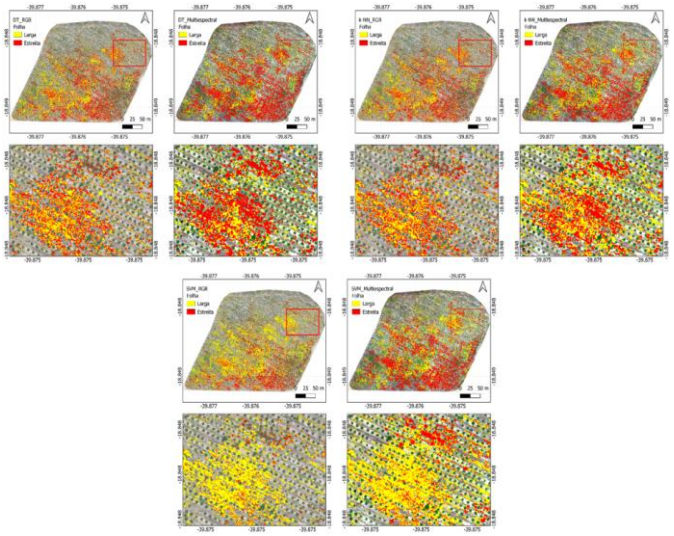


Figura 3. Classificação das plantas daninhas (folha larga e estreita) utilizando decision trees (DT), k-nearest neighbors (k-NN) e máquina de vetores de suporte (SVM) em imagens RGB e multiespectral.

Pelos resultados da Tabela 3, observa-se que os maiores valores para as métricas foram obtidos para as imagens multiespectrais e para a classificação das plantas daninhas de folhas estreita. As imagens multiespectrais geralmente permitem maior diferenciação de alvos, uma vez que a utilização da informação do NIR separa melhor a vegetação de outras feições (Lan et al., 2021).

TABELA 3. Métricas da classificação das plantas daninhas, por classificador utilizando os produtos dos sensores RGB e multiespectral.

Classificador	Folha	Precisão		Recall		f-score	
		Multi.	RGB	Multi.	RGB	Multi.	RGB
DT	Larga	0,69	0,59	0,65	0,54	0,67	0,56
	Estreita	0,79	0,67	0,74	0,53	0,76	0,59
k-NN	Larga	0,73	0,60	0,73	0,54	0,73	0,57
	Estreita	0,82	0,67	0,82	0,57	0,82	0,61
SVM	Larga	0,69	0,50	0,65	0,49	0,67	0,50
	Estreita	0,79	0,64	0,74	0,45	0,76	0,52

DT - decision trees; k-NN - k-nearest neighbors; SVM - máquina de vetores de suporte

Para o percentual de área coberta pelas plantas daninhas (Tabela 4), os maiores valores de área foram observados para folha estreita. Considerando as áreas da multiespectral como referência (melhores resultados para as métricas), é possível observar que o SVM para a imagem RGB, apresentou o pior resultado, superestimando as áreas com folha larga e subestimando aquelas com folha estreita.

TABELA 4. Percentual de cobertura de área pelas plantas daninhas (folha larga e estreita) estimada por diferentes algoritmos e produtos de sensoriamento remoto aéreo.

Classificador	Área F. Larga (%)		Área F. Estreita (%)	
	RGB	Multiespectral	RGB	Multiespectral
DT	15,88	14,15	16,71	26,52
k-NN	17,24	16,64	20,78	21,19
SVM	22,17	17,96	12,42	20,55

DT - decision trees; k-NN - k-nearest neighbors; SVM - máquina de vetores de suporte

As menores diferenças entre a classificação a partir das imagens RGB e multiespectral foi observada para o k-NN. Dyrman (2017) afirma que o k-NN é um ótimo classificador, desde que se atinja o número máximo ideal de amostras de treinamento.

CONCLUSÃO

Foi possível classificar plantas daninhas a partir da associação entre sensoriamento remoto aéreo e machine learning, separando-as de acordo com a sua morfologia em folhas largas e estreitas. Apesar dos melhores resultados com imagens multiespectrais, é possível utilizar imagens RGB para a classificação de plantas daninhas em área de produção de eucalipto.

REFERÊNCIAS

CASTRO, A.I.; TORRES-SÁNCHEZ, J.; PEÑA, J.M.; JIMÉNEZ-BRENES, F.M.; CSILLIK, O.; LÓPEZ-GRANADOS, F. An automatic random forest-OBIA algorithm for early weed mapping between and within crop rows using uav imagery. **Remote Sensing**. 10, 285, 2018.

DYRMAN, M. **Automatic Detection and Classification of Weed Seedlings under Natural Light Conditions**. University of Southern Denmark. 2017.

FLETCHER, R. S. Using vegetation índices as input into Random forest for soybean and weed classification. **American Journal of Plant Sciences**, v. 7, n. 15, p. 2186- 2198, 2016.

GHANIZADEH, H.; HARRINGTON, K. C. Weed management in New Zeland pastures. **Agronomy**, v. 9, n. 8, p. 448, 2019.

GHARDE, Y.; SINGH, P. K.; DUBEY, R. P.; GUPTA, P. K. Assessment of yield and economic losses in agriculture due to weeds in India. **Crop Protection**, v. 107, p. 12- 18, 2018.

HUNTER, J. E.; GANNON, T. W.; RICHARDSON, R. J.; YELVERTON, F. H.; LEON, R. G. Integration of remote?weed mapping and an autonomous spraying unmanned aerial vehicle for site?specific weed management. **Pest Management Science**, v. 76, n. 4, p. 1386-1392, 2020.

LAN, Y.; HUANG, K.; YANG, C.; LEI, L.; YE, J.; ZHANG, J.; DENG, J. Real-time identification of rice weeds by UAV low-altitude remote sensing based on improved semantic segmentation model. **Remote Sensing**, v. 13, n. 21, p. 4370, 2021.

ESTABILIDADE TEMPORAL DE MODELOS COM BASE EM XRF PARA PREDIÇÃO DE MAGNÉSIO EXTRAÍVEL E CTC EM SOLOS TROPICAIS

MARCOS MANTELLI RAGAGNIN [1]; GABRIEL TOLEDO MARQUES [1]; TIAGO RODRIGUES TAVARES [2]; HUDSON WALLACE PEREIRA DE CARVALHO [4]; JOSÉ PAULO MOLIN [3]

[1]Graduando. Piracicaba - SP. Depto. Engenharia de Biossistemas, Escola Superior de Agricultura Luiz de Queiroz, USP/ESALQ; [2]Engenheiro Agrônomo, Pesquisador Pós-Doc.. Piracicaba-SP. Centro de Energia Nuclear na Agricultura, CENA, USP; [3]Engenheiro Agrícola, Professor. Piracicaba-SP. Depto. Engenharia de Biossistemas, USP/ESALQ; [4]Químico, Professor. Benguerir, Marrocos.. University Mohammed VI Polytechnic

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Estudos utilizando a espectroscopia de fluorescência de raios X (XRF) para predição de nutrientes disponíveis no solo tem crescido nos últimos anos na área de ciência do solo e tem apresentado bons desempenhos preditivos. Recentemente foi demonstrado que há estabilidade temporal em modelos para predição de ex-Ca e ex-K, ou seja, modelos feitos em um ano podem ser extrapolados para o futuro em certos casos. Porém, não há estudos que avaliaram a estabilidade temporal de atributos secundários, ou seja, que não possuem linhas de emissão correspondentes no XRF (e.g., CTC e ex-Mg), portanto o objetivo do estudo foi avaliar a predição temporal desses modelos para atributos secundários de solo. Para isso foi utilizado um modelo de predição com um banco de dados de 2015, sendo extrapolado em amostras coletadas em 2019, 2020 e 2022 (realizando três coletas diferentes em 2022) na mesma área. Os resultados obtidos mostraram uma variação de desempenho em todos os anos que o modelo foi extrapolado, com RPIQ (Razão entre o desempenho e o intervalo entre quartis) variando entre 0,64 e 1,55, o que configura modelos pobres e razoáveis. Os resultados desse estudo de caso permitem concluir que modelos locais com dados XRF não apresentam estabilidade temporal para predição dos atributos secundários ex-Mg e CTC.

PALAVRAS-CHAVE: Sensoriamento Proximal do Solo; Espectrometria de Fluorescência de Raio X; Modelagem Preditiva

ABSTRACT

Studies using X-ray fluorescence spectroscopy (XRF) to predict available nutrients in the soil have been growing in recent years in the field of soil science and have shown good predictive performance. It has recently been shown that there is temporal stability in models for predicting ex-Ca and ex-K, i.e. models made in one year can be extrapolated into the future in certain cases. However, there are no studies that have evaluated the temporal stability of secondary attributes, i.e. those that do not have corresponding emission lines in the XRF (e.g. CTC and ex-Mg), so the aim of the study was to evaluate the temporal prediction of these models for secondary soil attributes. To do this, a prediction model was used with a database from 2015 and extrapolated to samples collected in 2019, 2020 and 2022 (three different samples in 2022) in the same area. The results obtained showed a variation in performance in all the years that the model was extrapolated, with RPIQ (Ratio between performance and the interval between quartiles) varying between 0.64 and 1.55, which configures poor and reasonable models. The results of this case study allow us to conclude that local models with XRF data do not show temporal stability for predicting the secondary attributes ex-Mg and CTC.

KEYWORDS: ;

INTRODUÇÃO

A espectrometria de fluorescência de raios X (XRF) é uma técnica de análise direta que permite inferências rápidas (em torno de 30 s) e de forma não destrutiva de amostras de solo (WEINDORF; CHAKRABORTY, 2020). Além disso, é alinhada com os princípios da Química Verde por evitar o uso de reagentes químicos nas análises, reduzindo assim o descarte de resíduos ambientais (GREDILLA ET AL., 2016). Sensores XRF têm potencial para ser embarcados em sistemas mecanizados de coleta para conduzir análises diretamente campo (TAVARES et al., 2023). Embora estes sensores mensurem o teor total dos elementos, estudos recentes mostram bons desempenhos (R^2 > 0,70) para inferir sobre atributos de fertilidade em solos tropicais, tais como textura (ANDRADE et al., 2020), nutrientes extraíveis (e.g. ex-Ca, ex-K e ex-Mg) (TEIXEIRA et al., 2018) e atributos químicos (e.g. saturação de bases (V%), capacidade de troca catiônica (CTC)) (SILVA et al., 2017). Porém, poucos estudos avaliaram a estabilidade temporal desses modelos preditivos, o que é importante para o amadurecimento desta tecnologia dentro da Agricultura de Precisão. Recentemente, os autores TAVARES et al. (2024, no prelo) avaliaram o desempenho de modelos locais de ex-Ca e ex-K calibrados em amostras coletadas em 2015 ao serem extrapolados em amostras coletadas em anos seguintes (e.g., 2019, 2020 e 2022). Os valores de R^2, RMSE e BIAS mantiveram padrões satisfatórios, com RPIQ maior que 1,86[DQ1] para os anos de 2019 e 2020, os quais não tiveram aplicações de insumos que alteraram a relação entre teores totais e extraíveis. Os autores ainda observaram que a aplicação de pó de rocha que alterem a relação desses teores pode comprometer a estabilidade temporal desses modelos. Esses estudos são incipientes e precisam ser mais explorados pela comunidade cientifica. Além disso, o estudo mencionado avaliou a estabilidade temporal apenas em atributos primários (ex-Ca e ex-K), ou seja, que tem relação direta com o espectro XRF. A predição dos atributos primários ex-Ca e ex-K ocorre devido sua relação com as linhas de emissão Ca-Kα e K-Kα. Por sua vez, os atributos secundários (e.g., ex-Mg e CTC), que não possuem linhas de emissão específicas no espectro XRF, ainda não foram explorados na literatura. Teores de ex-Mg e CTC são corriqueiramente preditos utilizando a linhas Ca-Kα como variável mais importante do modelo. Ao mesmo tempo, nestes casos de sucesso, os teores de ex-Ca e o atributo secundário em questão geralmente apresentam correlação entre si (TAVARES et al., 2020; RIBEIRO et al., 2024). Essas constatações dão uma natureza indireta para a inferência de atributos secundários com sensores XRF. Sugere-se que a estabilidade temporal de predições de atributos secundários dependeria tanto da estabilidade das relações inter atributo (e.g., ex-Ca e ex-Mg), quanto da estabilidade entre os teores totais e disponíveis do elemento que se relaciona com o atributo secundário (e.g., ex-Ca e Ca-Kα).

OBJETIVOS

O presente trabalho explora esse contexto e tem por objetivo avaliar a estabilidade temporal do desempenho dos modelos XRF para a predição de ex-Mg e CTC ao extrapolar esses modelos em amostras coletadas em diferentes anos.

MATERIAL E MÉTODOS

A área de estudo está situada na Fazenda Areão, propriedade da ESALQ - USP, em Piracicaba, SP. O monitoramento da área foi realizado entre 2015 e 2022 ao mesmo tempo que o manejo da área era realizado com o cultivo de diferentes culturas agrícolas, todas recebendo adubação de plantio e cobertura utilizando fontes solúveis de fertilizantes NPK e aplicações de calcário nos anos de 2015 e 2022 (doses entre 1000 e 9000 kg ha^{-1} em ambos os anos). Coletas de solo para a avaliação dos modelos com base em XRF foram realizadas nos anos de 2015 (designada C15), 2019 (C19), 2020 (C20) e 2022 (C22a, C22b, C22c), sendo que nesse último ano, foram feitas três coletas após a aplicação de diferentes doses de calcário para avaliar a influência dessa aplicação nos modelos preditivos. As doses foram aplicadas em diferentes parcelas instaladas na área nas doses de 0 kg/ha, 1000 kg/ha, 3000 kg/ha, 5000 kg/ha, 7000 kg/ha e 9000 kg/ha para calcário. Essas aplicações tiveram o objetivo de alterar a relação entre teor total e disponível do Ca, uma vez que o calcário apresenta solubilidade gradual (0,014 g L^{-1}) com efeito residual até 12 meses após a aplicação (MINATO et al.,

2023). A primeira coleta de 2022 foi realizada 30 dias após a aplicação, a segunda, 130 dias após a aplicação e, a terceira, 190 dias pós aplicação. Em todos os anos, foram coletadas 60 amostras de 0 a 10 cm de profundidade.

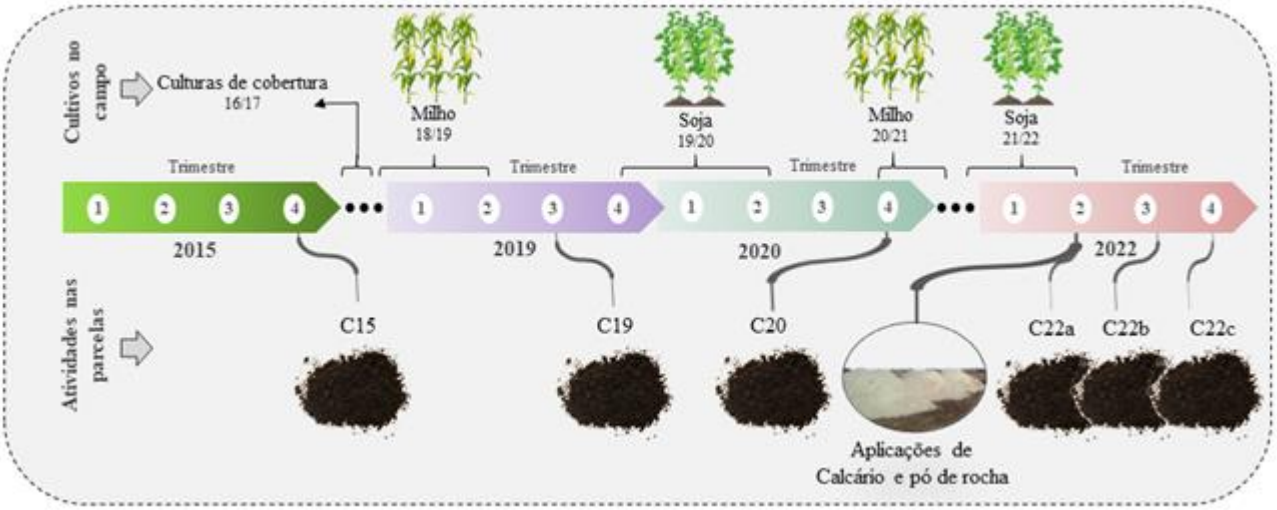


Figura 1 -Histórico de cultivos da área e intervenções de manejo entre 2015 e 2022.

Após as coletas, as amostram foram secas em estufa na temperatura de 45 °C, por 72 horas. Em sequência, as amostras foram peneiradas em peneira de malha de 2 mm e, em seguida, armazenadas em um local coberto e arejado. Análises com sensor XRF foram realizadas em todas as amostras após a última coleta. Para tal, cerca de 10 gramas foram depositados em uma cubeta de polietileno com fundo selado com filme de polipropileno de 4 μm de espessura (SPEX, Metuchen, NJ, EUA). As coletas foram realizadas em triplicata, com a posição da cubeta no sensor sendo alterada em cada coleta. O sensor utilizado foi um XRF portátil (Tracer-III-SD, Bruker AXS, Madison, WI, EUA), configurado com uma tensão e corrente do tubo de raios X de 35kV e 7μA, respectivamente. O tempo de análise foi de 30 segundos, conduzido sob pressão atmosférica (i.e., sem uso de vácuo) e sem a utilização de filtros. Cada amostra foi analisada em triplicata em posições diferentes, após mover levemente a cubeta no sensor. Os teores de ex-Mg foram determinados usando o método descrito por Gianello e Amorim (2015), com extração utilizando NH_4Cl 1 mol L^{-1} e quantificação por espectrometria de emissão ótica com plasma acoplado indutivamente (ICP-OES). No cálculo da CTC, que se dá pela adição entre a soma de bases (ex-Ca, ex-Mg e ex-K) e a acidez potencial ($H+Al^{+3}$), os componentes da soma de base foram determinados pelo mesmo método utilizado na determinação do ex-Mg. Já o $H+Al^{+3}$, foi quantificado via pH em solução SMP (Shoe Maker, McLean & Pratt). Para a verificação da estabilidade temporal das predições de ex-Mg e CTC, modelos foram calibrados com o banco de dados da C15 e, então, extrapolados para os bancos de dados C19, C20, C22a, C22b e C22c. Modelos utilizando regressão linear múltipla foi gerado para ex-Mg e CTC, ambos utilizando as linhas de emissão Kα do Ca, K, Si, Ti e Fe, além das linhas de espalhamento Rh-K e Rh-compton. A avaliação de desempenho dos modelos foi feita utilizando o coeficiente de determinação (R^2), a raíz quadrada do erro médio (RMSE), bias (erro sistêmico) e a Razão entre o desempenho e o intervalo entre quartis (RPIQ). O RPIQ foi calculado dividindo o intervalo interquartil dos valores de referência de toda a biblioteca local pelo RMSE de cada predição. A avaliação do RPIQ utilizou as seguintes classes de interpretação: modelos excelentes para o RPIQ > 2,5; modelos muito bons para 2,5 ≥ RPIQ > 2,0; modelos bons para 2,0 ≥ RPIQ > 1,7; modelos razoáveis para 1,7 ≥ RPIQ > 1,4; e modelos pobres para RPIQ ≤ 1,4. A Figura 2 ilustra em um fluxograma as etapas da modelagem.

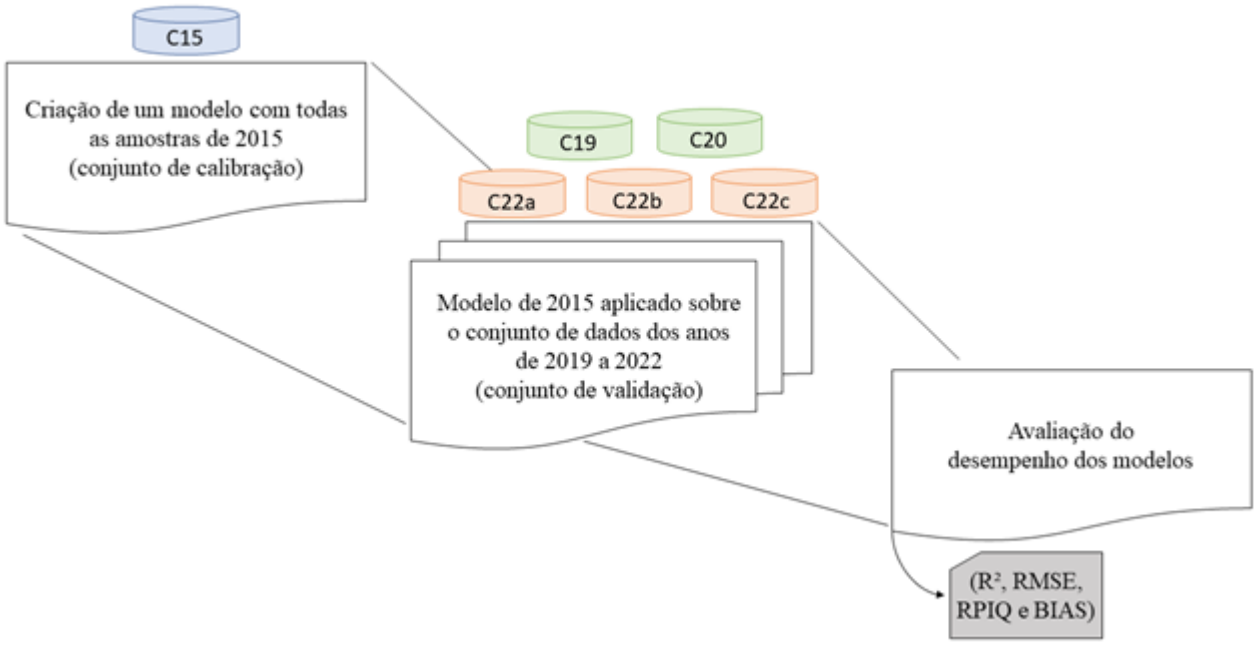


Figura 2 - Fluxograma da modelagem utilizada no trabalho para avaliar a estabilidade temporal do desempenho de modelos preditivos de ex-Mg e CTC usando dados XRF.

RESULTADOS E DISCUSSÃO

Nas Figuras 3 e 4 são apresentados, respectivamente, os gráficos de dispersão que relacionam os teores de referência e preditos de ex-Mg e CTC. O R^2 e análises das oscilações do RMSE e bias destes modelos são apresentadas na Tabela 2.

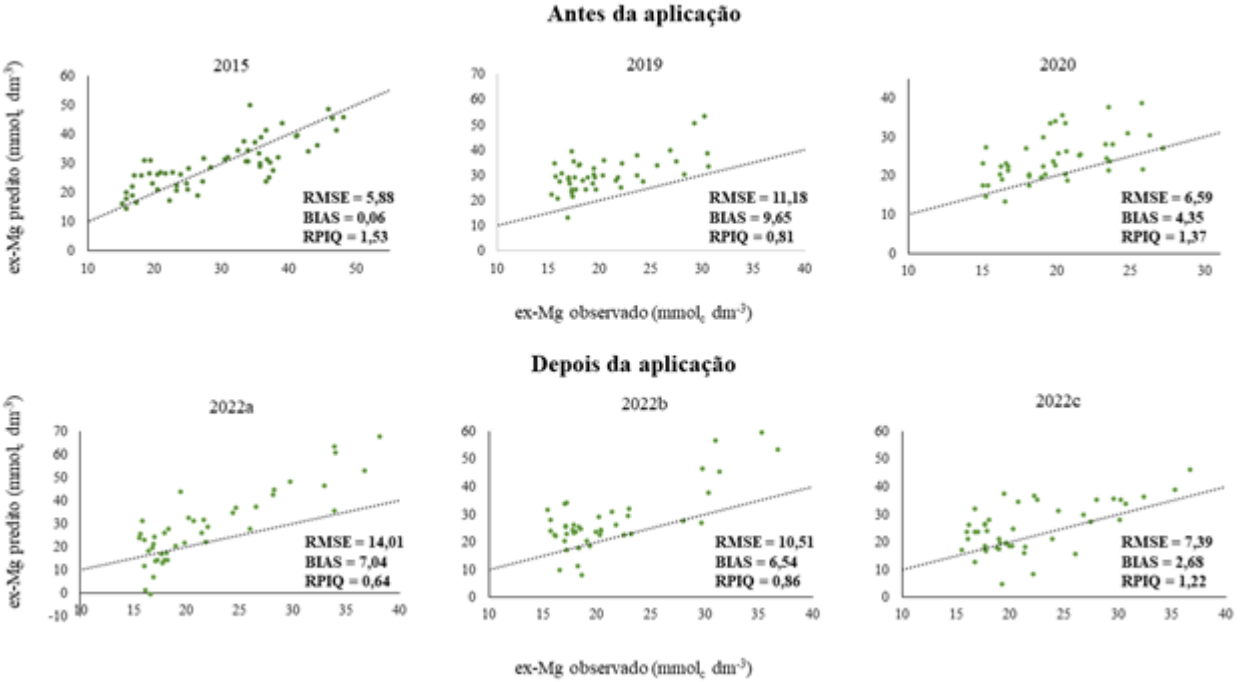


Figura 3 - Gráficos de dispersão dos teores de ex-Mg preditos versus os de referência usando os modelos calibrados no ano de 2015 e extrapolados para as amostras dos anos de 2019, 2020, 2022a, 2022b, 2022c.[DQ1] [mr2] [mr3]

[DQ1]De acordo com a publicação:

Piñeiro, G., Perelman, S., Guerschman, J. P., & Paruelo, J. M. (2008). How to evaluate models: observed vs. predicted or predicted vs. observed?. *Ecological modelling*, *216*(3-4), 316-322. no eixo x do gráfico de dispersão deve estar os valores preditos e no eixo y os valores experimentais.

[mr2]Entendo essa recomendação, mas conversando com meu orientador ele me disse que sempre foi orientado e até corrigido por pesquisadores como o Demattê e Abdul a colocar os valores preditos no eixo Y e os observado no eixo X. Seguem dois papers em revistas de alto impacto de pesquisadores renomados que mantiveram essa disposição dos gráficos: Yin-Chung Huang, Cho-Ying Huang, Budiman Minasny, Zueng-Sang Chen, Zeng-Yei Hseu,

Using pXRF and Vis-NIR for characterizing diagnostic horizons of fine-textured podzolic soils in subtropical forests, Geoderma, Volume 437, 2023, 116582, ISSN 0016-7061, https://doi.org/10.1016/j.geoderma.2023.116582. Nícolas Augusto Rosin, José A.M. Demattê, Hudson Wallace Pereira de Carvalho, Heidy Soledad Rodriguez-Albarracín, Jorge Tadeu Fim Rosas, Jean Jesus Novais, Ricardo S.D. Dalmolin, Marcelo Rodrigo Alves, Renan Falcioni, Nikolaos Tziolas, Sina Mallah, Danilo César de Mello, Márcio Rocha Francelino,

Spatializing soil elemental concentration as measured by X-ray fluorescence analysis using remote sensing data, CATENA, Volume 240, 2024, 107988, ISSN 0341-8162, https://doi.org/10.1016/j.catena.2024.107988.

[mr3]Caso ainda recomende que se invertam os eixos posso fazer sem problemas.

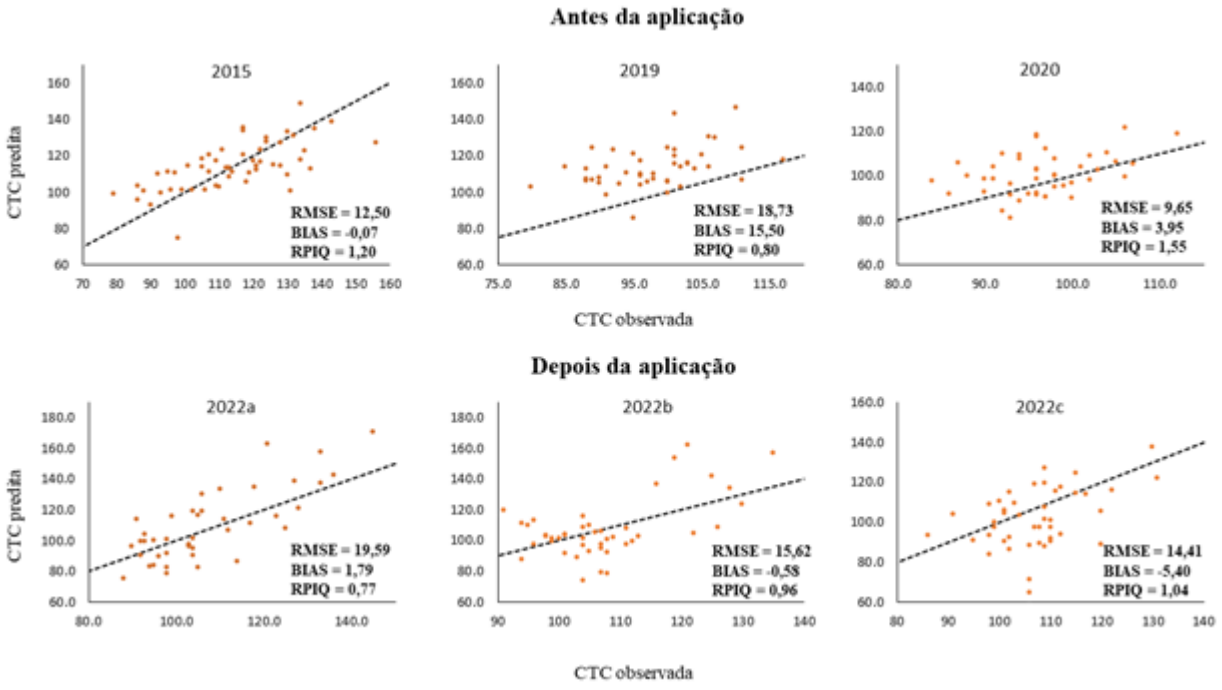


Figura 4 - Gráficos de dispersão dos valores de CTC preditos versus os de referência obtidos com os modelos calibrados no ano de 2015 e extrapolados para as amostras dos anos de 2019, 2020, 2022a, 2022b, 2022c.

É possível observar que o RMSE tanto para a predição temporal de ex-Mg, quanto para a de CTC, apresentou comportamento instável ao longo dos diferentes anos, indicando a instabilidade temporal do modelo calibrado em 2015. Por exemplo, para ex-Mg, a modelagem de 2015 teve o valor mais baixo (5,88 $mmol_c\ dm^{-3}$), em 2019 subiu 90%, chegando a 11,18 $mmol_c\ dm^{-3}$, voltando a reduzir em 2020, quando apresentou RMSE de 6,59 $mmol_c\ dm^{-3}$ (aumento de apenas 12% em relação a 2015). O RMSE para ex-Mg chegou ao valor máximo em 2022a, com valor de 14,01 $mmol_c\ dm^{-3}$, um aumento de 138% em relação a 2015. Já para CTC, o RMSE iniciou em 2015 com o valor de 12,50 $mmol_c\ dm^{-3}$, e logo no ano de 2019 houve um aumento de 50%, indo para 18,73 $mmol_c\ dm^{-3}$. Em 2020, o RMSE diminuiu em relação à 2015, obtendo valor de 9,56 $mmol_c\ dm^{-3}$, um comportamento não esperado. Por outro lado, voltou a subir em 2022a, quando atingiu seu valor máximo de 19,59 $mmol_c\ dm^{-3}$ (aumento de 57% em relação a 2015). Tanto para ex-Mg, quanto para CTC, o Bias em 2015 (momento da calibração dos modelos) é o menor da série histórica, com valor de 0,06 para ex-Mg e -0,07 para CTC, representando apenas 1% do RMSE observado para o ex-Mg e 0,56% do RMSE observado para a CTC naquele momento. À medida que os modelos são extrapolados, o bias sobe, passando a representar entre 36 e 86% do RMSE de ex-Mg e entre 3,7% e 83% para CTC (Tabela 2). Assim como observado para o RMSE, o bias não tem comportamento estável temporalmente. Além da instabilidade do desempenho preditivo de ex-Mg e CTC, mostrado pela oscilação temporal do RMSE e bias, os modelos de forma geral apresentaram desempenho de RPIQ ruim ao serem extrapolados para os anos seguintes. A análise dos valores indica que a modelagem variou de modelos razoáveis até pobres com base na classificação de qualidade do RPIQ. Ao considerarmos os valores de RPIQ menores que 1,4 como modelos ruins e entre 1,4 e 1,7 como[DQ1] razoáveis, das 12 predições, 10 delas apresentaram desempenho ruim e 2 foram razoáveis (ex-Mg em 2015 e CTC em 2020). Com base nas avaliações apresentadas acima, pode-se inferir que os modelos gerados por XRF os atributos secundários CTC e ex-Mg não possuem estabilidade temporal. Não houve estabilidade temporal já nos anos iniciais (2019 e 2020), em que o manejo da área não havia sido modificado devido as aplicações de pó de rocha. Ou seja, acredita-se que a instabilidade temporal desses modelos não depende unicamente da relação entre teores totais e disponíveis, tal como observado por (Tavares et al., 2024) para ex-Ca e ex-K. Sendo assim, acredita-se que oscilações entre as inter-relações do ex-Ca com CTC e ex-Mg seja a causa da instabilidade de desempenho nos anos iniciais de 2019 e 2020, quando aplicações de pó de rocha ainda não haviam sido realizadas.

Tabela 2 - Variação no RMSE durante os anos em relação ao RMSE de 2015 e porcentagem do erro sistemático (Bias) em relação ao RMSE de cada um dos anos avaliados. Todos os resultados são apresentados para ex-Mg e CTC.

	2015	2019	2020	2022a	2022b	2022c
			ex-Mg			
Variação RMSE	--	90%	12%	138%	79%	25%
Bias no RMSE	1%	86%	66%	50%	62%	36%
R^2	0,63	0,37	0,28	0,71	0,62	0,36
			CTC			
Variação RMSE	--	50%	-23%	57%	25%	15%
Bias no RMSE	0,56%	83%	41%	9%	3,7%	37%
R^2	0,45	0,17	0,15	0,55	0,33	0,19

A razão entre os teores de ex-Ca o ex-Mg e a CTC, apresentada nas Figuras 5 e 6, permitem entender a relação entre esses atributos ao longo dos anos. Observando a razão entre ex-Ca e ex-Mg, em 2015 observou-se que ela oscilou entre um valor mínimo e máximo de 1,36?3,35, o qual foi reduzido em 2019 (valor mínimo e máximo de 1.75?3,06) e 2020 (valor mínimo e máximo de 1,69?2,81). Em 2022a, a amplitude subiu (valor mínimo e máximo de 1,80?2,93), em seguida, caindo ligeiramente e se estabilizando nas amostragens seguintes de 2022b e 2022c (com valor mínimo de 1.68 e máximo de 2.73). Esse comportamento temporal errático também foi observado para relações locais entre ex-Ca e CTC. Em 2015, obteve-se valor mínimo e valor máximo de 0,41 e 0,62, respectivamente, com a maior amplitude em relação aos demais anos, bem como o maior valor máximo dentro dessa amplitude. No ano de 2019 e 2020 a amplitude reduziu progressivamente, mostrando valores mínimos e máximos entre 0,39 e 0,53 em 2019, e entre 0,41 e 0,50 em 2020. Nos anos após aplicação de corretivos os valores mínimos e máximos oscilaram entre 0,36 e 0,55 em 2022a, 0,37 e 0,52 em 2022b e 0,37 e 0,53 nas em 2022c. Vale destacar que a relação entre ex-Ca e os demais atributos oscilou menos nas coletas de 2022, realizadas em datas mais próximas entre si, oscilando mais entre os diferentes anos. Com base nesses dados, pode-se observar que dentre os anos plotados na Figura 5, o banco de dados com maior amplitude nas razões ex-Ca:ex-Mg e ex-Ca:CTC foi o de 2015 e que ele também possuiu valores máximos mais elevados do que nos anos subsequentes. Essa diferença na amplitude pode explicar a não estabilidade temporal no desempenho dos modelos, principalmente nos anos de 2019 e 2020 que não havia influência da aplicação de pó de rocha. A predição tanto do ex-Mg e da CTC neste banco de dados tem a linha de emissão do Ca como variável principal. Portanto, a estabilidade temporal dos modelos também depende da estabilidade da relação dos teores de ex-Ca com os atributos secundários. O presente trabalho mostra um estudo de caso com experimento de longo prazo em que a determinação de atributos secundários, tal como o ex-Mg e a CTC, utilizando modelos XRF calibrados em amostras de anos anteriores não mostrou estabilidade temporal no desempenho preditivo. A oscilação temporal da relação entre teores totais e disponíveis de Ca (observada principalmente para as coletas dos anos de 2022 (Tavares et al., 2024)), junto com a variação das relações entre ex-Ca e os atributos secundários preditos, devem ser as causas da alta variação do desempenho preditivo do modelo XRF observado. O presente trabalho indica que modelos com base XRF locais para predição de atributos secundários devem ser utilizados apenas para predições realizadas no momento em que as amostras foram coletadas, garantindo um cenário mais estável das relações que garantem essa predição.

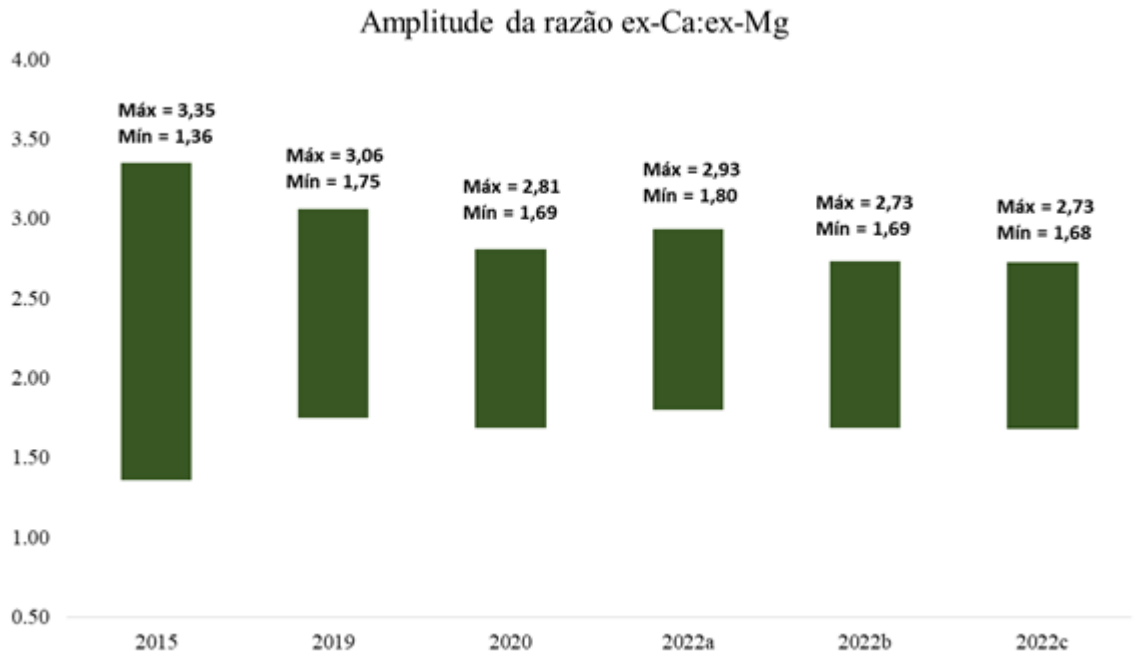


Figura 5 - Gráficos da amplitude dos valores da razão entre ex-Ca e ex-Mg para os bancos de dados de 2015, 2019, 2020, 2022a, 2022b e 2022c.

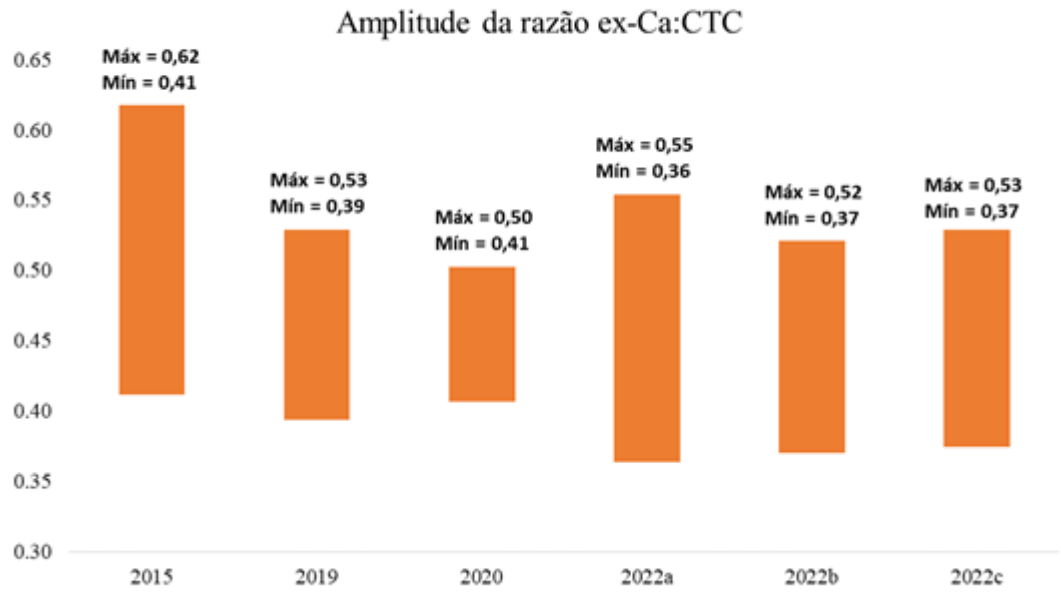


Figura 6 - Gráficos da amplitude dos valores da razão entre ex-Ca e CTC para os bancos de dados de 2015, 2019, 2020, 2022a, 2022b e 2022c.

CONCLUSÃO

Este estudo abordou a estabilidade temporal da predição de atributos secundários (e.g., ex-Mg e CTC), que não apresentam linha de emissão no espectro XRF, utilizando os dados deste sensor. Ao extrapolar modelos calibrados em 2015 em amostras coletadas em anos seguintes para predição de atributos secundários, observou-se a perda de desempenho dos modelos, tanto pelo aumento do RMSE, quanto do bias. O estudo lança luz sobre as causas para essa instabilidade de desempenho, que pode ser relacionada a dois fatores: (i) alteração da relação entre ex-Ca:ex-Mg e ex-Ca:CTC e (ii) alteração da relação entre Ca total e ex-Ca após a aplicação dos pós de rocha de 2022; enfatiza-se as relações do Ca com os atributos secundários, pois este atributo é a principal variável do XRF nos modelos dos atributos secundários.

AGRADECIMENTOS

Agradecemos a fundação AGRISUS pelo apoio financeiro no projeto (PA 3411/22)

REFERÊNCIAS

AMORIM, M.B.; Rogeri, D.A., Gianello, C., 2021. Potassium Available to Corn Plants Extracted by Ammonium Acetate, Ammonium Chloride, Mehlich-1 and Mehlich-3 Solutions in Southern Brazilian Soils. **Commun. Soil Sci. Plant Anal**. 52, 1790-1797. 2021.

ANDRADE, R.; FARIA, W.M.; SILVA, S.H.G.; CHAKRABORTY, S.; WEINDORF, D.C.; MESQUITA, L.F.; GUILHERME, L.R.G.; CURI, N. Prediction of soil fertility via portable X-ray

fluorescence (pXRF) spectrometry and soil texture in the Brazilian Coastal Plains. **Geoderma**, v. 357, 1 jan. 2020.

BOEIRA, R.C.; Raij, B. van; Silva, A.S.; Maximiliano, V.C.B. Extração simultânea de alumínio, cálcio, magnésio, potássio e sódio do solo com solução de cloreto de amônio. **Rev. Bras. Ciência do Solo** 28, 929-936. 2004.

GIANELLO, C., A.; M.B. Ammonium Chloride Solution as an Alternative Laboratory Procedure for Exchangeable Cations in Southern Brazilian Soils. **Commun. Soil Sci. Plant Anal**. 46, 94-103. 2015.

GREDILLA, A.; Fdez-Ortiz V.; S., Elejoste, N.; de Diego, A.; Madariaga, J.M. Non destructive Spectroscopy combined with chemometrics as a tool for Green Chemical. Analysis of environmental samples: A review. **TrAC Trends Anal. Chem**. 76, 30-39. 2016.

MINATO, E.A.; Brignoli, F.M.; Neto, M.E.; Besen, M.R.; Cassim, B.M.A.R.; Lima, R.S.; Tormena; C.A., Inoue, T.T.; Batista, M.A. Lime and gypsum application to low-acidity soils: Changes in soil chemical properties, residual lime content and crop agronomic performance**. Soil Tillage Res**. 234, 105860. 2023.

MOLIN, J.P.; TAVARES, T.R. Sensor systems for mapping soil fertility attributes: challenges, advances, and perspectives in brazilian tropical soils. **Engenharia Agrícola**, v.39, p.126-147, 2019.

RIBEIRO, J.V. et al. Optimization of pXRF instrumentation conditions and multivariate modeling in soil fertility attributes determination. **Spectrochimica Acta Part B: Atomic Spectroscopy**, v. 211, p. 106835, 2024.

SILVA, S.H.G.; TEIXEIRA, A.F.D.S.; MENEZES, M.D.D.; GUILHERME, L.R.G.; MOREIRA, F.M.D.S.; CURI, N. et al. Regressão linear múltipla e random forest para predição e mapeamento de atributos do solo utilizando dados de espectrômetro portátil de fluorescência de raios-X (pXRF). **Ciencia e Agrotecnologia**, v. 41, n. 6, p. 648-664, 1 nov. 2017.

TAVARES, T.R.; MOLIN, J.P.; NUNES, L.C.; ALVES, E.E.N.; MELQUIADES, F.L.; CARVALHO, H.W.P.; MOUAZEN, A.M. Effect of X-Ray Tube Configuration on Measurement of Key Soil Fertility Attributes with XRF. **Remote sensing**. v. 12, p. 963, 2020.

TAVARES, T.R.; Molin, J.P.; Alves, E.E.N.; Melquiades, F.L.; de Carvalho, H.W.P.; Mouazen, A.M. Towards rapid analysis with XRF sensor for assessing soil fertility attributes: Effects of dwell time reduction. ***Soil and Tillage Research***, *232*, p.105768. 2023

TAVARES, T. R. et al. Do XRF local models have temporal stability for predicting plant-available nutrients in different years? A long-term study showing the effect of soil fertility management in a tropical field. **Soil & Tillage Research.** 2024, no prelo.

TEIXEIRA, A. F. DOS S. et al. Portable x-ray fluorescence (pXRF) spectrometry applied to the prediction of chemical attributes in inceptisols under different land use. **Ciencia e Agrotecnologia**, v. 42, n. 5, p. 501-512, 1 set. 2018.

WEINDORF, D.C.; CHAKRABORTY, S. Portable X?ray fluorescence spectrometry analysis of soils. **Soil Science Society of America Journal**, v. 84. n. 5, p.1384-1392, 2020.

MAPEAMENTO DA TEXTURA DO SOLO A PARTIR DE SENSORES DE CONDUTIVIDADE ELÉTRICA (CEa) E SUSCETIBILIDADE MAGNÉTICA (SM)

João Vítor Fiolo Pozzuto [1]; Lucas Rios do Amaral [2]
[1]Mestrando em Engenharia Agrícola. Av. Cândido rondon, 501. Campinas-SP. Faculdade de Engenharia Agrícola da Unicamp; [2]Professor Associado. Av. Cândido rondon, 501. Campinas-SP. Faculdade de Engenharia Agrícola da Unicamp

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
Técnicas de sensoriamento de solo podem ser utilizadas como alternativa aos altos custos envolvidos em densas grades amostrais, necessárias para o bom mapeamento da variabilidade espacial de atributos físico-químicos do solo. Apesar de sensores serem amplamente estudados para o mapeamento, são escassos os trabalhos que estudem a complementariedade destes. Por isso, o objetivo desse trabalho foi estudar a complementariedade de 2 sensores de Condutividade Elétrica aparente (CEa) e 2 sensores de Suscetibilidade Magnética (SM) para mapeamento do teor de argila. Para isso, 258 amostras de solo foram coletadas em uma área produtora de grãos de 103ha. As leituras coletadas foram utilizadas para análise de complementariedade/redundância de sensores a partir de correlação linear de Spearman, regressões lineares múltiplas (RLM) e modelos de Random Forest (RF), com modelos para todas as combinações entre sensores. Houve alta colinearidade entre 3 dos sensores (r: 0,96 - 0,98). Além disso, observou-se acurácia significativamente maior para os modelos RF em relação aos modelos de regressão linear. Conclui-se que os 4 sensores trazem informações redundantes (não complementares) e que a SM é mais diretamente ligada ao teor de argila dos solos, cabendo ao usuário a decisão de utilizar o equipamento de campo ou laboratorial para medição da SM, uma vez que apresentaram métricas semelhantes.

PALAVRAS-CHAVE: Sensoriamento Proximal; Textura do solo; Mapeamento digital de solos

ABSTRACT
Soil sensing techniques can be used as an alternative to the high costs involved in dense sampling grids, which are necessary to map the spatial variability of soil physicochemical attributes accurately. Although sensors are widely studied for digital mapping of attributes, few studies have investigated their complementarity. Therefore, this study aimed to assess the complementarity of two ECa and two MS sensors for mapping clay content. A 103 ha grain-producing area was selected, where 258 soil samples were collected. The sensor readings were used for complementarity/redundancy analysis through Spearman's linear correlation, multiple linear regressions (MLR), and Random Forest (RF) models, with models for all sensor combinations. High collinearity was observed between three of the sensors (r: 0.96-0.98). Additionally, RF models showed significantly higher accuracy than linear regression models. The results suggest that the four sensors have redundant readings (not complementary) and that MS is more directly related to clay content in soils. The decision whether to use field or laboratory equipment for MS measurement lies with the user, once both show similar capability for clay mapping.

KEYWORDS: Proximal Sensing; Soil Texture; Digital Soil Mapping

INTRODUÇÃO

Pela Agricultura de Precisão (AP) ser uma estratégia de gestão que considera a variabilidade espacial e temporal das lavouras para maior sustentabilidade da produção agropecuária (ISPA, 2024), é

necessário o mapeamento das propriedades físico-químicas dos solos, que por sua vez, necessitam de uma densa grade amostral para seu adequado mapeamento (CHERUBIN et al., 2014, 2022; DO AMARAL; JUSTINA, 2019; PUSCH et al., 2021; RAMOS et al., 2021). Entretanto, a coleta e análise de solos em uma grade densa é onerosa ao usuário, o que limita a sua utilização prática, demandando alternativa mais viável economicamente.

Dentre as propriedades físico-químicas dos solos a serem mapeadas, é sabido que a argila desempenha importante papel, uma vez que está diretamente relacionada a diversas outras propriedades, tanto químicas quanto físicas. Técnicas de sensoriamento de solo, em suas mais diferentes formas, são alternativa para caracterização de sua variabilidade espacial (CASTRIGNANÒ et al., 2017; CHERUBIN et al., 2022; MOLIN; AMARAL; COLAÇO, 2015). Um dos tipos de sensor mais estudados para o mapeamento da variabilidade espacial da textura do solo são os sensores de eletromagnetismo induzido (EMI), que por meio da resposta do solo à indução de campos eletromagnéticos em determinadas frequências, permitem a leitura da Condutividade Elétrica aparente (CEa) (CORWIN; LESCH, 2005; MEDEIROS et al., 2018) e/ou da Suscetibilidade magnética (SM) (BRANDÃO et al., 2023; DE SOUZA BAHIA et al., 2017; RAMOS et al., 2021). Apesar de inúmeros sensores disponíveis e vários estudos referentes a sua utilização em mapeamento da variabilidade, são escassos os trabalhos que foquem na complementariedade ou redundância dos sensores para mapear os atributos do solo.

OBJETIVOS

O objetivo deste trabalho foi verificar se há complementariedade dos dados de sensores, em específico de SM e CEa, para mapeamento da variabilidade espacial da argila em solos agrícolas.

MATERIAL E MÉTODOS

Uma área de 103 ha situada no município de Cosmópolis-SP (22º42' S e 47º11' O) (FIGURA 1) foi adota para esse estudo, onde produz-se grãos via semeadura direta em duas safras ao ano desde 2015. Segundo a classificação de Köppen's, aplicada por Alvares et al. (2013) para o Brasil, o clima pode ser classificado como Cfa, clima subtropical úmido com clima oceânico, sem estações secas e com verões quentes. Além disso, possui precipitação média anual entre 1300 e 1600mm e temperatura média entre 20 e 22 °C. Por fim, a área possui relevo levemente ondulado e é coberta por Latossolos e Gleissolos, com texturas variando de 19,4 a 65,5% de argila.

Nessa área, em outubro de 2020, foram coletadas amostras de solo na camada 0 - 0,2m, a uma densidade de, aproximadamente, 2 amostras.ha^{-1}, totalizando 258 amostras (FIGURA 1), que foram enviadas a laboratório comercial, para determinação de teor de argila do solo (< 0,002 mm, em g kg^{-1}). Tais amostras foram coletadas a partir de 4 subamostras dentro de um raio de 4 metros utilizando broca automatizada instalada em um quadriciclo.

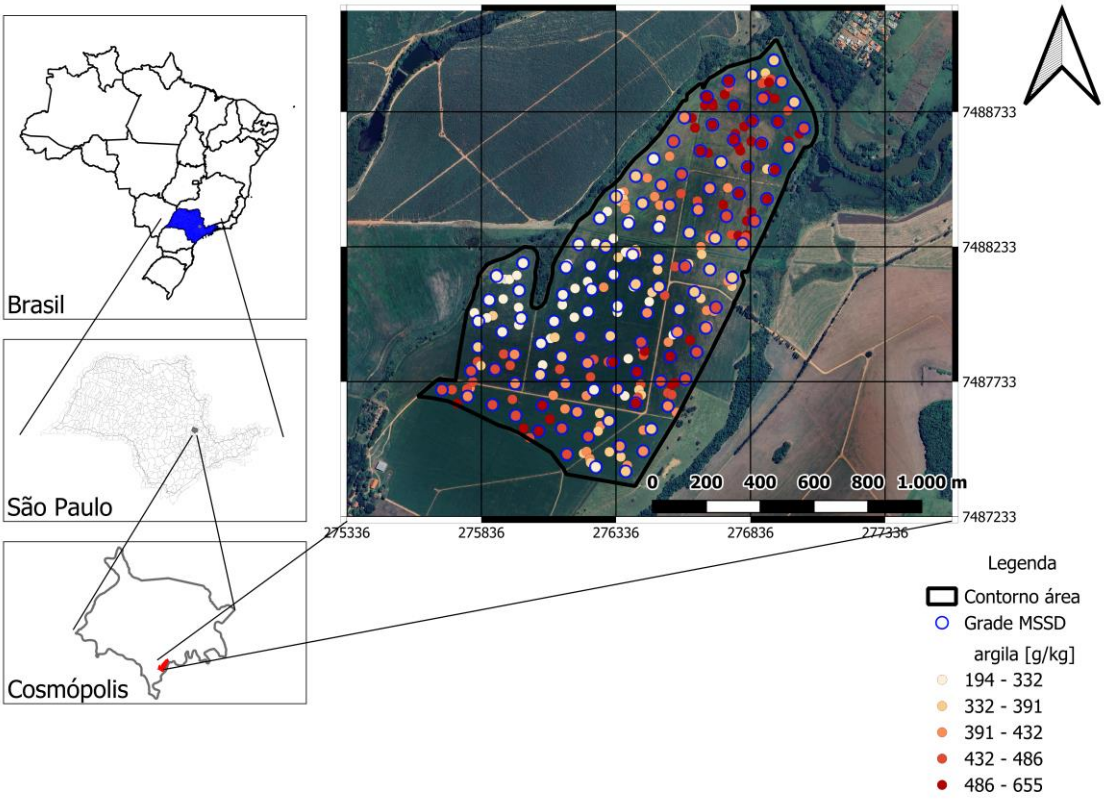


FIGURA 1. Mapa de localização da área de estudos e alocação dos pontos de amostra de solo, com teor de argila classificado [g/kg], bem como da grade utilizada nas interpolações por krigagem.

Dois sensores comerciais de EMI tracionados por quadriciclo foram utilizados para medição da CEa, chamados aqui apenas de "sensor-1" e o "sensor-2". Além disso, o sensor-2 também coleta, simultaneamente, dados de SM, sendo outra medida utilizada. Ambos os sensores foram conduzidos a uma velocidade de, aproximadamente, 15 km h^{-1} e com passadas a cada 30m. Tanto o sensor-1 quanto o sensor-2 coletam dados em mais de uma profundidade, porém sendo escolhidas para trabalho as profundidades mais superficiais, conforme configurações de fábrica, sendo a camada de 0 - 0,5m para o sensor-1 e 0 - 0,375m para o sensor-2. Essa camada mais superficial de cada sensor foi escolhida porque as amostras de solo em estudo foram coletadas na camada 0 - 0,2 m de profundidade. Para contemplar mais tipos de sensores EMI, um sensor comercial de bancada (sensor-$_{lab}$) de medição de SM foi utilizado diretamente nas amostras de solo coletadas após passarem pela análise em laboratório, assegurando já estarem secas e peneiradas a 2 mm, não exigindo mais preparação além do acondicionamento destas nos recipientes de leitura fornecidos junto ao equipamento. O sensor-$_{lab}$ foi utilizado no modo de baixa frequência (*Low Frequency* - LF) e na configuração de tempo sugerida (para solos) pelo manual do equipamento, com leitura de referência do ar de 5s (equivalente à tara do equipamento), seguida de leitura da amostra por mais 5s e uma validação final de 5s do valor de referência inicial do ar.

A utilização dos sensores 1 e 2 resulta em dados pontuais densos, isto é, geram pontos com informação da leitura a cada poucos centímetros ou metros ao longo de cada passada, sendo todos georreferenciados via GNSS (Global navigation satellite system - sistema de navegação global por satélites). Já o sensor lab, por ser utilizado diretamente nas amostras de solo, resulta em dados pontuais esparsos, de mesma forma e localização que a determinação laboratorial da argila, já que essas foram as amostras lidas pelo sensor. Para ser possível o estudo das quatro leituras dos sensores era necessário, portanto, colocalizar as leituras às amostras de solo e, para isso, os dados dos sensores 1 e 2 foram interpolados e seu valor extraído nos pontos de amostra. Para a interpolação, primeiramente os dados tiveram seus valores anômalos removidos em software SIG, tanto de forma

global quanto local (considerando os vizinhos próximos), bem como identificação de manobras e valores externos ao contorno da área. Então foram passados pelo aplicativo MapFilter, seguindo metodologia descrita por Maldaner, Molin e Spekken (2022), garantindo uma segunda remoção de pontos anômalos a nível global (todo conjunto de dados) e local (considerando a variabilidade dos pontos próximos entre si). Então, foram interpolados por meio de krigagem ordinária utilizando o plugin Smart-Map do QGIS (PEREIRA et al., 2022), sendo para tal feita a análise e ajuste do semivariograma. Logo, com os mapas dos sensores 1 e 2 interpolados, foi possível colocalizar as informações, também em software SIG, ao extrair o valor dos mapas gerados sobre os pontos onde foram coletadas as amostras de solo, gerando uma base de dados, que posteriormente foi exportada ao software estatístico R.

No R foi calculada a correlação linear de Spearman (r), com nível de confiança de 95% ($p \leq 0,05$), para se avaliar tanto a colinearidade (em termos numéricos) entre as leituras dos sensores, quanto a relação entre a medida de cada sensor e a argila, entendendo assim o quão próxima de um modelo linear ($Y= b_0+b_1x_1$) é (ou não) a relação da leitura com o teor de argila. Para os posteriores passos de análise dos dados, as variáveis de sensoriamento foram normalizadas/centralizadas (mín-máx) (Eq. 1), para que os valores de todas estejam na mesma escala de valores (de 0 a 1), evitando assim com que escalas maiores infiram maiores importâncias às variáveis, e para facilitar a interpretação do comportamento das diferentes leituras dos sensores com uma mesma variável de resposta (argila). Para entender o resultado numérico das correlações, foram feitas também representações gráficas das interações entre cada sensor.

$$X_C = (X - X_{mín}) / (X_{máx} - X_{mín}) \quad (1)$$

em que: Xc - valor centralizado, X - valor medido pelo sensor, $X_{mín}$ - mínimo valor medido pelo sensor dentre os dados, $X_{máx}$ - máximo valor medido pelo sensor dentre os dados.

Ainda, foi avaliada a relação dos dados dos sensores com a argila, sendo avaliados os modelos de regressão linear simples (RLS) referente a cada variável, com seus respectivos coeficientes de determinação (R^2). Além disso, no R, foi feito um modelo de regressão linear múltipla (RLM) utilizando as combinações de leituras de todos os sensores, para avaliar se haveria ganhos de acurácia ao acrescentar os sensores individualmente (Figura 2). De forma a avaliar o melhor modelo de RLS ou RLM, em mesmo software foi aplicado um algoritmo de regressão por *Stepwise*, sendo escolhido, dentre os três tipos disponíveis, o modelo híbrido (uma junção dos modelos *forward* e *backward*) (JAMES et al., 2017), que avalia tanto se a variável adicionada ao modelo trouxe ganhos de acurácia, como se alguma das já existentes deixou de contribuir para o modelo, gerando ao fim o melhor modelo para utilização de 1, de 2, de 3 e de 4 sensores simultaneamente.

Ademais, para englobar modelos de predição não lineares, foram feitos modelos RF (BREIMAN, 2001), a partir do pacote *mlr* no R (BISCHL et al., 2016; R CORE TEAM, 2023), para as 15 combinações possíveis de sensores, destacadas em verde na Figura 2 e com um número (ID) de cada modelo. Para modelos RF criados pelo *mlr* no R é necessário definir os parâmetros *ntree* e *mtry*, os quais podem ser definidos manualmente ou por meio da busca (*tuning*) de hiperparâmetros, sendo a segunda a opção escolhida. Para isso foi aplicado o método *Grid Search* utilizando como intervalos de busca 50 a 500 para *ntree* e para *mtry* de 1 até a quantidade de variáveis para cada modelo (logo, de 1 a 4). Ainda, para que os modelos pudessem ser treinados e testados, a tabela de dados foi dividida aleatoriamente em conjunto de treino com 70% dos dados, totalizando 183, e de teste, com 30% dos dados, totalizando 75, sendo todas as métricas obtidas a partir do conjunto de teste, não utilizado no treinamento do modelo.

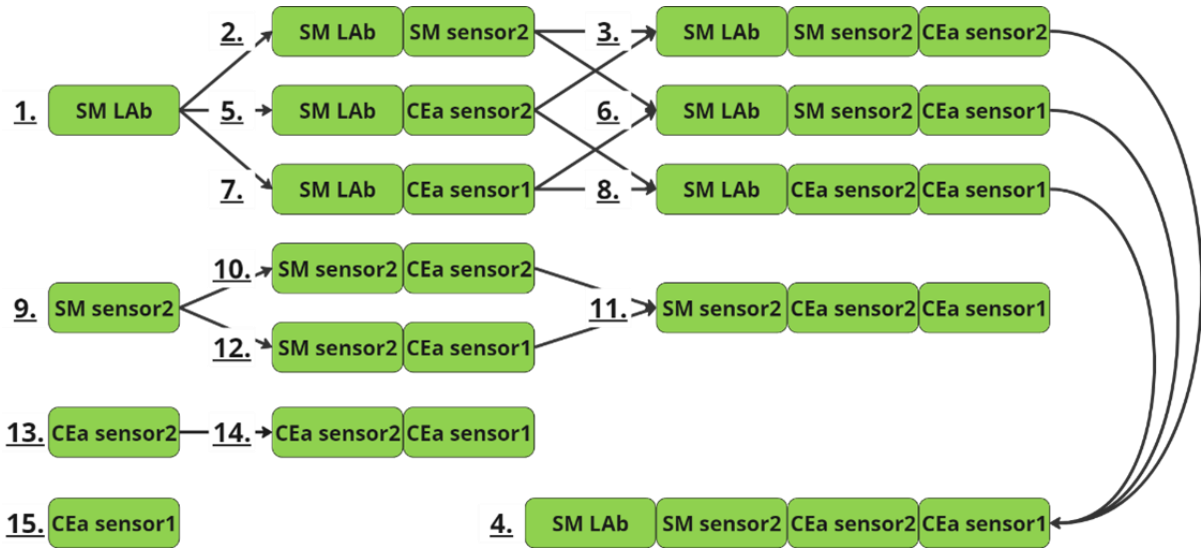


FIGURA 2. Modelos RF criados a partir das 15 combinações únicas possíveis e o "ID" do modelo

Para avaliação do desempenho de cada um dos modelos foi calculado o coeficiente de determinação (R^2) e o RMSE (raíz do erro quadrático médio) percentual, sendo utilizadas para verificar se, partindo de um único sensor há ganho de acurácia do modelo ao se adicionar um segundo, e assim por diante (setas da Figura 2). Além disso, para comparar os efeitos das modelagens lineares e por RF, os melhores modelos de RLM e RF foram avaliados para entender se relações lineares são bons modelos para predição de argila ou se são necessários modelos não lineares como os de RF.

Além disso, a partir de parte dos pontos de amostras de argila (109 amostras), circulados em azul na Figura 1, foi gerado um mapa interpolado por krigagem ordinária (KO) utilizando o pacote *gstat* no R. As demais amostras (149 pontos) foram utilizadas como amostras de validação para avaliação da qualidade da interpolação, comparando o valor real, obtido das amostras de solo, com o valor predito, extraído do mapa interpolado. Buscando avaliar se o mapeamento da SM do solo pode ajudar na criação dos mapas de solo, a krigagem com deriva externa (KED) foi utilizada para a predição do teor de argila, seguindo os mesmos pontos para interpolação e análise, sendo assim possível entender se essa informação do sensor conseguiu melhorar a modelagem da variabilidade espacial da argila.

RESULTADOS E DISCUSSÃO

A partir da correlação linear de Spearman de todas as variáveis, foi possível verificar que as quatro leituras dos sensores têm correlação linear numericamente parecida entre si com a argila, variando (em módulo) de 0,50 a 0,57, além de uma alta colinearidade entre os sensores (0,96 - 0,98), exceto para a CEa do sensor-1, que apresentou menores correlações com os demais sensores, e com a argila, provavelmente por apresentar variações grandes entre talhões vizinhos (Figura 3), também visível na CEa do leitor 2, em menor escala. Isso pode demonstrar que o sensor 1, provavelmente capturou diferentes operações de solo entre os talhões, acarretando menor relação com a argila. Para avaliar de forma mais detalhada a interação da leitura dos sensores, as combinações possíveis entre os sensores foram colocadas (com valores centralizados) em gráficos (Figura 4), que confirmam a colinearidade da leitura de todos os sensores em exceção à CEa do sensor 1, que se mostrou mais dispersa frente às outras medições, indicando um maior ruído nos dados ou relações não lineares (modelos de primeiro grau) entre diferentes sensores. Com isso, é possível indicar que os sensores, sobretudo o sensor-2 (ambas SM e CEa) e o sensor lab têm leituras redundantes.

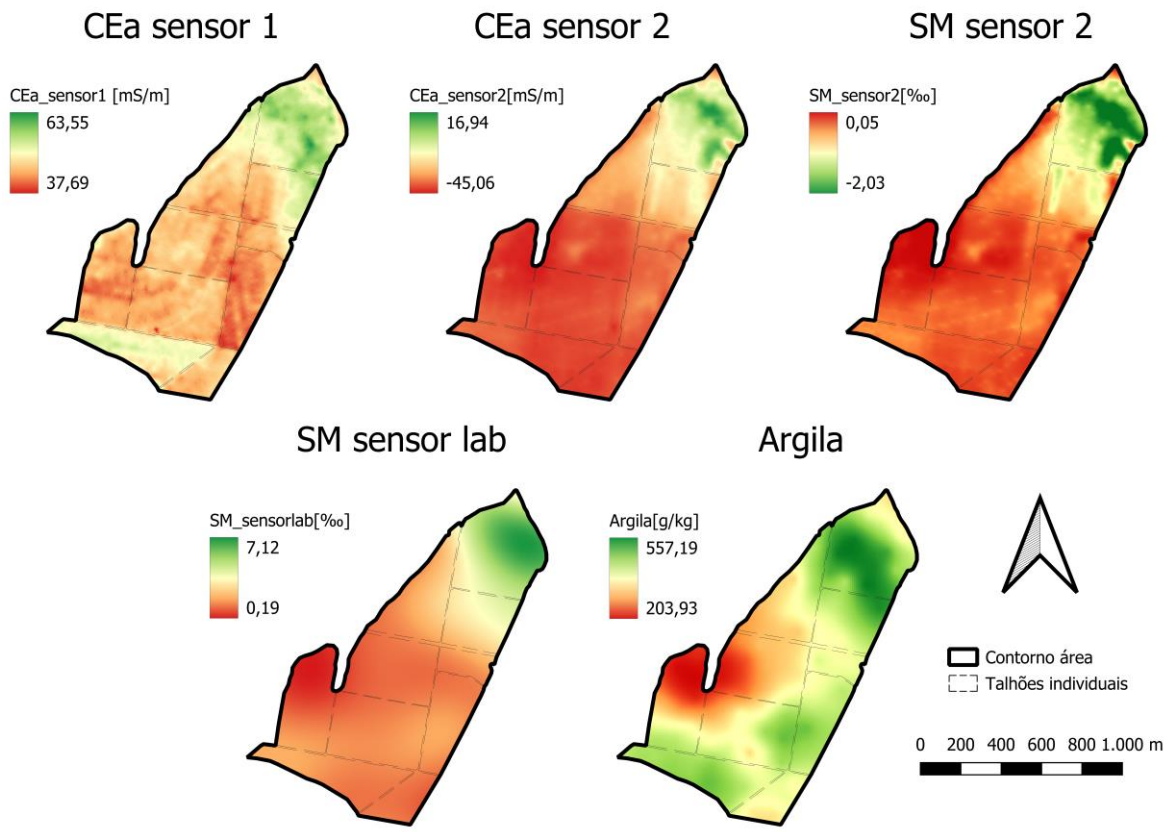


FIGURA 3. Mapas das leituras dos sensores EMI utilizados e de argila.

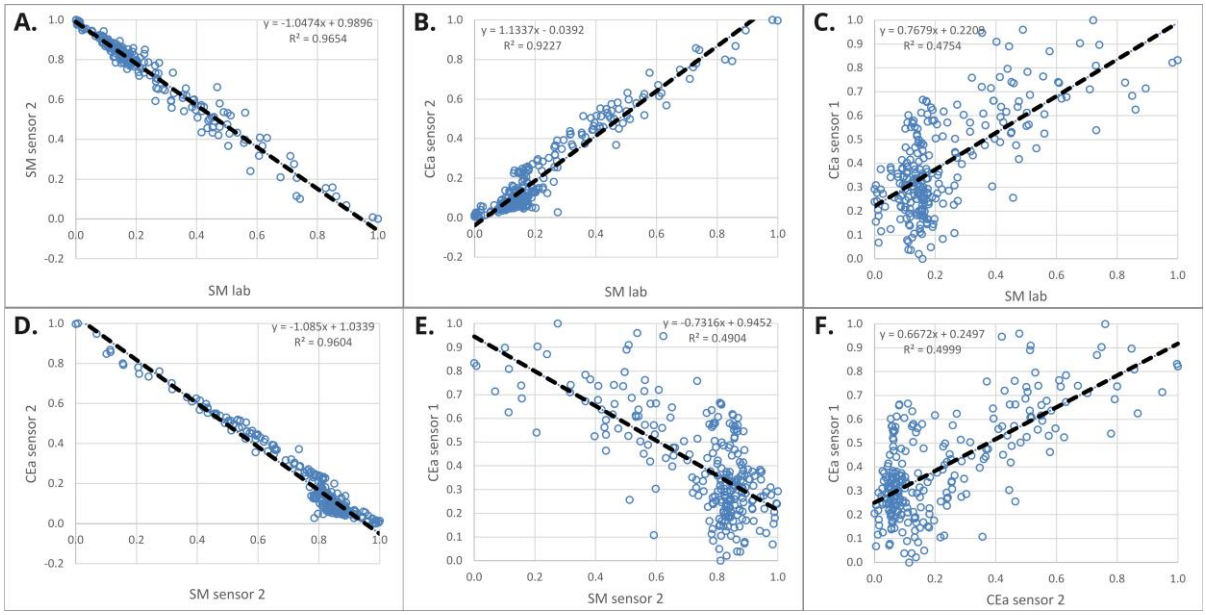


FIGURA 4. Correlação entre as leituras (centradas) dos sensores e modelo de tendência linear entre a leitura dos sensores.

A partir do gráfico das leituras dos sensores em relação ao teor de argila (%) e seus respectivos modelos de regressão linear simples (Figura 5), foi possível confirmar a redundância dos sensores em modelos lineares, ao apresentaram comportamento semelhante conforme a variação da argila, evidenciado pelo coeficiente angular (em módulo) dos modelos, que variou de 0,0011 a 0,0013. Cabe a ressalva de que o SM do sensor 2 possui relação inversamente proporcional, mas comportamento semelhante, confirmado pelos gráficos de correlação entre sensores (Figura 4).

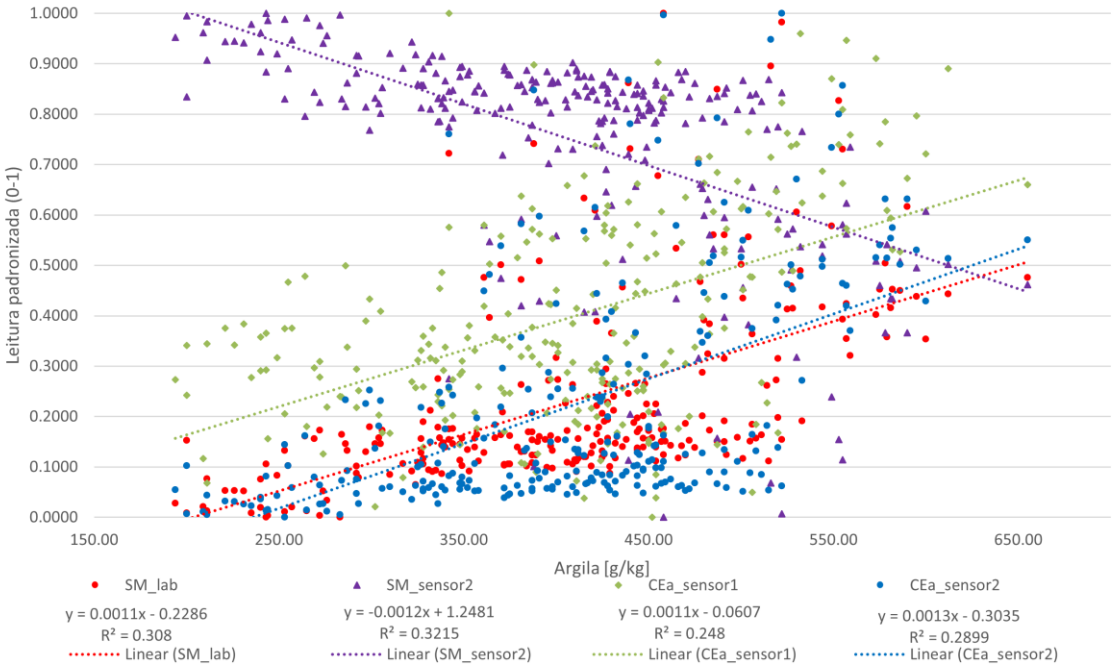


FIGURA 5. Modelos de regressão linear de argila para cada leitura (centralizada) dos sensores.

Uma vez que os modelos de RLS de cada sensor separado não apresentaram boas métricas (R^2) de desempenho (Tabela 1), um modelo de RLM para cada combinação de sensor foi criado, sendo possível entender que os sensores SM apresentaram melhor desempenho que os de CEa para mapeamento de argila. Não só, regressões lineares não apresentaram boa acuraria, tendo o modelo com melhor resultado um R^2 de somente 0,35, indicando, novamente, que relações lineares podem não ser os modelos que melhor relacionam esses sensores com a argila. Em relação à complementariedade, houve pouca ou nenhuma melhora do R^2 e RMSE% dos modelos quando mais sensores foram adicionados, principalmente quando comparados aos modelos contendo isoladamente os sensores de SM, indicando a redundância dos sensores. Mesmo comportamento se deu a partir da regressão linear por *stepwise* que, ao selecionar o melhor modelo por adição e subtração de variáveis (*stepwise* tipo híbrido) para cada nível de modelo (quantidade de sensores por modelo), indicados por * na Tabela 1, não apresentou melhoras significativas de R^2 e RMSE%.

TABELA 1. Métricas de desempenho (R^2 e RMSE%) para as amostras de teste dos modelos de regressão linear múltipla (RLM) e Random Forest (RF) para cada combinação de sensores.

		RLM		RF	
Modelo	Variáveis	R^2	RMSE %	R^2	RMSE %
1	SM lab	0,308	18,875	0,626	14,891
2	SM lab + SM sensor2	0,322	18,688	0,619	15,029
3	SM lab + SM sensor2 + CEa sensor2	0,329	18,582	0,612	15,163
4*	SM lab + SM sensor2 + CEa sensor2 + CEa sensor1	0,354	18,389	0,649	14,415
5	SM lab + CEa sensor2	0,308	18,870	0,612	15,161
6	SM lab + SM sensor2 + CEa sensor1	0,342	18,411	0,645	14,499

7	SM lab + CEa sensor1	0,333	18,526	0,638	14,637
8	SM lab + CEa sensor2 + CEa sensor1	0,334	18,522	0,642	14,552
9*	SM sensor2	0,322	18,662	0,578	15,807
10	SM sensor2 + CEa sensor2	0,329	18,586	0,517	16,916
11**	SM sensor2 + CEa sensor2 + CEa sensor1	0,353	18,301	0,601	15,368
12*	SM sensor2 + CEa sensor1	0,342	18,378	0,616	15,088
13	CEa sensor2	0,290	19,121	0,519	16,886
14	CEa sensor2 + CEa sensor1	0,317	18,747	0,596	15,471
15	CEa sensor1	0,248	19,677	0,288	20,530

* Modelos escolhidos pela regressão *stepwise* para 1, 2, 3 e 4 sensores; ** Melhor modelo dentre os selecionados por *stepwise*.

Foi também analisado o desempenho de modelos RF para os mesmos conjuntos de sensores (Tabela 1), que indicou uma significativa melhora dos modelos, a partir dos valores de R^2 (exceto para o modelo 15), propondo que modelos não lineares destes sensores possuem melhor relação que os lineares para a argila. Utilizando o conjunto de testes (30% dos pontos - 75 dados), não utilizado no treino dos modelos, o gráfico de predito versus observado (Figura 6), dos melhores modelos para RLM (conjunto 3) e RF (conjunto 5) possibilita identificar que o modelo RF representou melhor os dados que o modelo linear uma vez que a linha de relação (vermelha) estava mais próxima à linha 1x1 (cinza), corroborando com o encontrado de que modelos não lineares são melhores nesse caso.

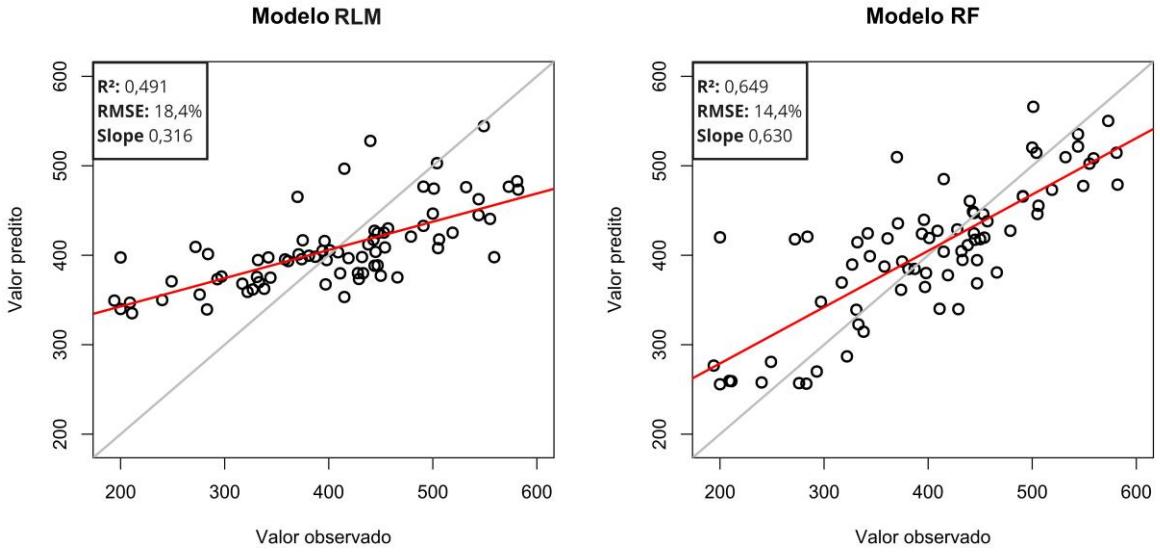


FIGURA 6. Gráficos de valor predito vs. Observado para o melhor modelo de regressão linear múltipla (RLM) e Random Forest (RF).

A partir das métricas dos modelos da Tabela 1, é possível entender que, por mais que tenha havido melhora em alguns dos modelos ao adicionar mais sensores, as diferenças são pequenas, não valendo a pena os custos envolvidos na utilização/compra de mais sensores. Além disso, o melhor desempenho individual de sensores se deu para a SM, tanto laboratorial quanto de campo, com acurácias similares, cabendo ao usuário decidir qual utilizar, de acordo com as condições de

amostragem: caso já tenha sido feita a coleta de amostras de solo para envio a laboratórios, recomenda-se o sensor laboratorial; caso contrário, e/ou para uma maior densidade de informação, sugere-se o sensor de campo.

Sabendo disso, foi escolhida a leitura de SM do sensor 2 para utilização como covariável na KED que, assim como a KO, foi modelada a partir do modelo esférico de semivariograma. A utilização da covariável não melhorou a predição por interpolação dos dados de argila, diminuindo ligeiramente o R^2 de 0,752 para 0,746 e aumentando ligeiramente o RMSE% de 11,5 para 11,6%, bem como comportamento semelhante dos gráficos de valores preditos e reais (Figura 7). Isso indica que o sensor não ajudou a mapear a variabilidade da argila via interpolação, possivelmente pela densidade amostral de treino (0,5 amostras.ha^{-1}) ser alta para a argila, que implicou em um modelo de KO satisfatório, mesmo sem o emprego da covariável (SM) no procedimento de interpolação espacial.

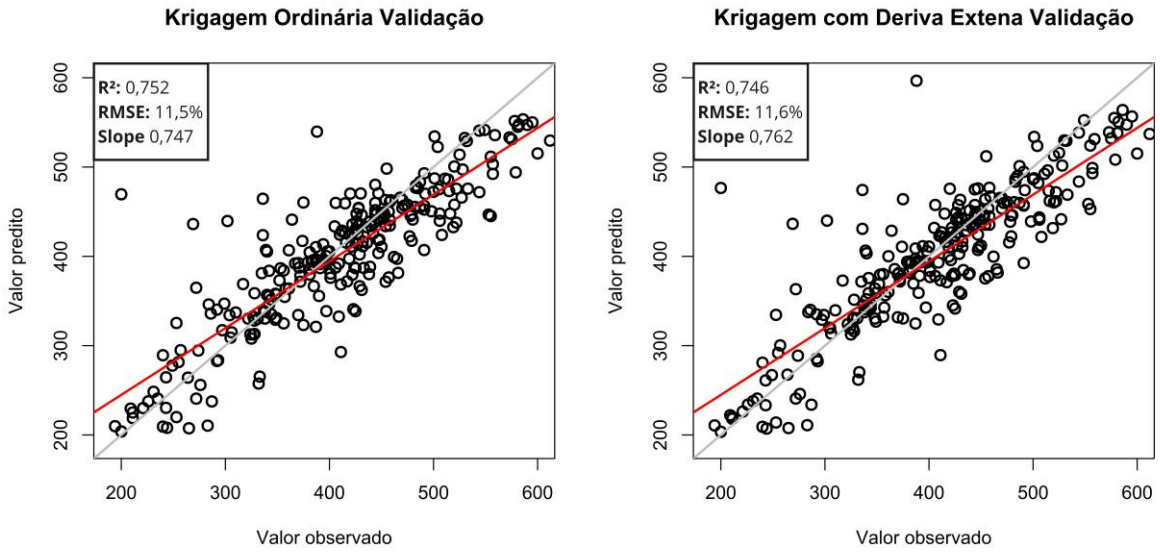


FIGURA 7. Gráficos de valor predito vs. observado de argila para a KO e KED utilizando a SM do sensor 2 como variável auxiliar (deriva).

CONCLUSÃO

Os sensores de SM e CEa testados trazem informações redundantes (não complementares) entre si para o mapeamento digital de argila, havendo ganhos muito pequenos em acurácia de modelo (R^2 e RMSE%) quando mais de um sensor é utilizado.

AGRADECIMENTOS

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado de São Paulo, processos n° 2022/03160-8 e 2023/02532-1; à Dra. Maiara Pusch pela coleta e disponibilização de parte dos dados utilizados neste trabalho; e ao IBRA MegaLab pelo empréstimo do equipamento laboratorial de Suscetibilidade Magnética.

REFERÊNCIAS

ALVARES, C. A. et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013.

BISCHL, B. et al. **mlr: Machine Learning in R. Journal of Machine Learning Research**. [s.l: s.n.]. Disponível em: <https://github.com/mlr-org/mlr>.

BRANDÃO, Z. N. et al. **Suscetibilidade magnética na estimativa de atributos físicos e químicos do solo**. Anais do XX Simpósio Brasileiro de Sensoriamento Remoto. **Anais**...abr. 2023. Disponível em: <https://proceedings.science/p/164623?lang=pt-br>

BREIMAN, L. Random Forests. **Machine Learning**, v. 45, p. 5-32, 2001.

CASTRIGNANÒ, A. et al. A combined approach of sensor data fusion and multivariate geostatistics for delineation of homogeneous zones in an agricultural field. **Sensors (Switzerland)**, v. 17, n. 12, p. 1-20, 2017.

CHERUBIN, M. R. et al. Eficiência de malhas amostrais utilizadas na caracterização da variabilidade espacial de fósforo e potássio. **Ciência Rural**, v. 44, n. 3, p. 425-432, 2014.

CHERUBIN, M. R. et al. Precision Agriculture in Brazil: The Trajectory of 25 Years of Scientific Research. **Agriculture (Switzerland)**, v. 12, n. 11, 2022.

CORWIN, D. L.; LESCH, S. M. Apparent soil electrical conductivity measurements in agriculture. **Computers and Electronics in Agriculture**, v. 46, n. 1- 3 SPEC. ISS., p. 11-43, 2005.

DE SOUZA BAHIA, A. S. R. et al. Prediction and Mapping of Soil Attributes using Diffuse Reflectance Spectroscopy and Magnetic Susceptibility. **Soil Science Society of America Journal**, v. 81, n. 6, p. 1450-1462, 2017.

AMARAL, L. R.; JUSTINA, D. D. D. Spatial dependence degree and sampling neighborhood influence on interpolation process for fertilizer prescription maps. **Engenharia Agrícola**, v. 39, n. specialissue, p. 85-95, 2019.

ISPA. **Precision Ag Definition | International Society of Precision Agriculture**. Disponível em: <https://www.ispag.org/about/definition>. Acesso em: 24 mar. 2024.

JAMES, G.; Witten, D.; Hastie T.; Tibshirani, R. **An introduction to statistical learning: with applications in R**. 7th ed, Springer, v. 1, 2017.

MALDANER, L. F.; MOLIN, J. P.; SPEKKEN, M. Methodology to filter out outliers in high spatial density data to improve maps reliability. **Scientia Agricola**, v. 79, n. 1, 2022.

MEDEIROS, W. N. et al. Apparent soil electrical conductivity in two different soil types. **Revista Ciência Agronômica**, v. 49, n. 1, p. 43-52, 2018.

MOLIN, J. P.; AMARAL, L. R.; COLAÇO, A. F. **Agricultura de precisão**. 1. ed. São Paulo: Oficina de textos, 2015.

PEREIRA, G. W. et al. Smart-Map: An Open-Source QGIS Plugin for Digital Mapping Using Machine Learning Techniques and Ordinary Kriging. **Agronomy**, v. 12, n. 6, 2022.

PUSCH, M. et al. SOIL PROPERTIES MAPPING USING PROXIMAL AND REMOTE SENSING AS COVARIATE. **Engenharia Agricola**, v. 41, n. 6, p. 634-642, 2021.

RAMOS, P. V. et al. Magnetic susceptibility in the prediction of soil attributes in southern Brazil. **Soil Science Society of America Journal**, v. 85, n. 1, p. 102-116, 2021.

R CORE TEAM. **R: A Language and Environment for Statistical Computing**. Vienna, Austria, 2023. Disponível em: <https://www.R-project.org/>.

PLATAFORMAS DE AQUISIÇÃO DE DADOS ALTIMÉTRICOS PARA DEMARCAÇÃO DE CURVAS DE NÍVEL EM ARROZ IRRIGADO

Charles Nunes da Silva [1]; Érique Almeida Conce Maciel [2]; Chaiane Guerra da Conceição [3]; Lanes Beatriz Acosta Jaques [3]; Vinícius dos Santos Cunha [3]

[1]Proprietário. Rua Dr. Nilo Milano 306, casa, bairro Lara, Alegrete RS, cep 97.545-200. Charles Soluções Tecnológicas; [2]Técnico. Av. Assis Brasil, 2109 - Centro - Cidade Alta, Alegrete - RS, 97543-000. Alvorada Sistemas Agrícolas - John Deere Alegrete; [3]Docente. Av. Tiarajú nº 810, Bairro Ibirapuitã, Alegrete, RS. CEP: 97546-550. Universidade Federal do Pampa - Campus Alegrete

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A cultura do arroz irrigado (*Oryza sativa* L.), de relevada importância global, é cultivada em diferentes sistemas, sendo um deles sobre taipas, para permitir irrigação por inundação. Uma das etapas dos projetos de irrigação dessa cultura é o levantamento de dados altimétrico que, quando sujeito a imprecisões, reduz a uniformidade da irrigação e, por consequência, a produtividade da cultura. Com isso, o objetivo deste trabalho foi avaliar a qualidade das curvas de nível geradas por três diferentes plataformas e metodologias de aquisição de dados altimétricos. O trabalho contou com três metodologias de coleta, que são: coleta de dados com drone e correção da altimetria com pontos de controle e verificação, denominada como PC; coleta de dados com drone com correção da altimetria em pós processamento, denominada como PPK; coleta de dados com o uso de RTK embarcado em veículo automotivo, denominada como RTK. Os resultados demostraram que as curvas geradas por RTK e PPk são muito semelhantes, em quase todo o campo avaliado. Porém, os dados gerados pela metodologia que usa drone e correção por pontos de controle e verificação apresentou valores de elevação que modificaram o sentido das curvas de nível em alguns pontos do campo avaliado. Constatou-se maiores diferenças em locais com declividade do terreno em torno de 1% ou menos, sendo que RTK e PPK foram similares em todos os níveis de declividade, conforme análise de correlação dos dados.

PALAVRAS-CHAVE: altimetria; drones; RTK

ABSTRACT

The rice crop (*Oryza sativa* L.), which has a global importance on food security, is grown in different systems, one of which is on levees to allow the flood irrigation. One step of irrigation projects for this crop is the elevation data collection. When data is collected under inaccuracies it reduces irrigation uniformity and then crop yield. Therefore, the goal of this study was to assess the quality of contour lines generated by three different platforms and methodologies for elevation data collection. The study employed the three following methodologies: data collection with drone and elevation correction with ground control points, referred to as PC; data collection with drone and post-processing elevation correction, referred to as PPK; data collection using RTK embedded in a small truck, referred to as RTK. The results showed that the contour lines generated by RTK and PPK are very similar across almost the entire evaluated field. However, the data generated by the methodology using drones and ground control points presented elevation values that changed the direction of the contour lines at some points in the evaluated field. Greater differences were observed in areas with terrain slope around 1%, or less with RTK and PPK being similar across all slope levels, according to the correlation analysis.

KEYWORDS: ;;

INTRODUÇÃO

Dentre as operações mais comuns no cultivo do arroz irrigado está a demarcação e construção de curvas de nível, que servem como pequenos diques para o barramento da água, permitindo assim a irrigação por inundação em áreas onde a sistematização do solo com corte e aterro é inviável (SOSBAI, 2012). Pode-se dizer que essa operação esteve por muitos anos na dependência de equipamentos que, apesar de boa precisão e acurácia, tem sua execução sujeita a erros de operação ocasionando, muitas vezes, desuniformidade na irrigação, aumentando consumo de água e reduzindo produtividade. Esses equipamentos referem-se ao chamado nível laser (BUENO et al., 2019). Porém, o advento de tecnologias como a correção de posicionamento em tempo real, utilizando sistema RTK, tem permitido otimizar esse processo.

De acordo com BUENO et al. (2019), o uso do RTK para demarcação das curvas de nível em lavouras de arroz irrigado tende a aumentar a acuraria do levantamento em comparação ao nível laser. Ainda, os autores observaram que em zonas de menor declividade (menores que 0,16% nesse caso), as diferenças entre os dois sistemas são ainda maiores. É um problema recorrente nas lavouras arrozeiras a irrigação justamente nas áreas mais planas, mesmo que o senso comum leve a uma lógica contrária de pensamento, principalmente na operação do nível laser. Em outras palavras, demarcar corretamente curvas de nível em um terreno plano é na verdade mais complexo (NARESH et al., 2014). Com isso, o trabalho de BUENO et al. (2019) valida a possibilidade de redução ou eliminação desse problema nas lavouras de arroz irrigado.

Convém salientar que a área cultivada com arroz irrigado, que demanda anualmente a demarcação de curvas de nível, no RS (estado com maior área de arroz irrigado no Brasil), é em torno de 90%, de uma área que na safra 2022/23 foi de 839.972,00 hectares (IRGA, 2023). Nessas áreas se observa uma migração para o uso do RTK, em detrimento do nível laser. Porém, algumas questões dificultam o uso do RTK, principalmente os relacionados ao levantamento para obtenção dos dados de elevação. O RTK é comumente embarcado em tratores (SILVA et al., 2014), sendo que produtores e técnicos têm adaptado para uso em carros, camionetas, quadriciclos, dentro outros. Além do consumo de combustível e o tempo necessário para operação, esse tipo de plataforma de aquisição do dado é dependente das condições meteorológicas, sendo que é necessário o solo seco para um bom levantamento. Com isso, surge a oportunidade de utilização de outras plataformas para obtenção dos dados de elevação, como os drones. É sabido que o uso de drones vem tem grande expansão na agricultura (COELHO et al., 2018; HAMANN, 2018; AMARAL et al., 2020), mas ainda com poucos trabalhos estudando sua viabilidade de uso frente ao RTK embarcado em tratores ou outros veículos.

OBJETIVOS

O objetivo deste trabalho foi avaliar a qualidade das curvas de nível geradas por três diferentes plataformas e metodologias de aquisição de dados altimétricos.

MATERIAL E MÉTODOS

O trabalho foi realizado em uma propriedade rural na cidade de Alegrete/RS situada a 2,5 quilômetros do centro cidade, com latitude de 29°46'14,24"S e longitude de 55°45'23,14"O, com área total de 13,29 ha. A área utilizada possui desnível irregular, com uma diferença, aproximada, 4,3 metros entre seu ponto mais alto e mais baixo. A área, no momento da execução dos levantamentos, estava pronta para receber as curvas de nível, ou seja, a superfície do terreno já havia sido preparada de modo a uniformizar seu micro relevo.

O estudo foi constituído de três métodos de coleta de dados planialtimétricos, para criação do projeto de suavização do terreno: 1) coleta de dados utilizando drone de baixa autonomia de voo, com correção da elevação por meio de pontos de controle e de verificação utilizando RTK de mão, com

denominação de PC; 2) coleta de dados utilizando drone de alta autonomia de voo, marca modelo Nuvem Spectral 2, com correção de da trajetória obtida com pós-processamento cinemático (PPK), sem pontos de controle e de verificação, com denominação de PPK; 3) coleta de dados utilizando sistema RTK embarcado em um veículo automotivo, com denominação de RTK. O RTK, foi considerada como a metodologia padrão, em função de que em outros trabalhos como o de BUENO et al. (2019) seu uso teve resultados superiores ao do sistema Laser e em função da migração que os produtores estão fazendo para o uso do RTK.

Procedimento de coleta e análise envolvendo o uso de drone e correção da elevação com pontos de controle e verificação (PC)

Os pontos coletados com a base RTK de mão foram obtidos a partir da delimitação de pontos alocados estrategicamente no talhão. A delimitação dos pontos se deu no software Quantim GIS®, e sua navegação em campo foi feita utilizando o aplicativo de celular QField®. Esses pontos foram demarcados no solo com o auxílio de cal hidratada, para posteriormente fossem reconhecidos nas imagens e assim serem utilizados como pontos de controle e verificação durante o processamento das imagens obtidas, sendo 15 usados como pontos de controle e seis como pontos de verificação. A Figura 1 ilustra a distribuição dos pontos no campo. Os pontos de controle e verificação coletados, assim como o ponto base, passaram por pós processamento, utilizando o serviço de pós-processamento de dados GNSS do Instituto Brasileiro de Geografia e Estatística (IBGE), para seu georreferenciamento e ajuste das coordenadas x, y e z. Foi utilizada uma base RTK marca Shouth™ modelo SHT 82, e seu Rover de mão da marca Shouth SHT 86, com uma coletora de mão da marca Geotac MD-75 com precisão vertical de 1,5 cm de precisão e 3 cm de precisão horizontal. O drone utilizado nessa foi o DJI mini2™. Como configuração de voo, utilizou-se altura de voo de 60 metros, com sobreposição frontal de 85% e lateral de 65%, a uma velocidade de 8 km/h. O voo foi executado de forma automática, por meio do aplicativo de celular DroneHarmony®. As imagens coletadas foram processadas no software WebODM™ para a criação do modelo digital de elevação, sendo que o que os dados altimétricos obtidos foram extraídos e trabalhados no software Quantum GIS ®.

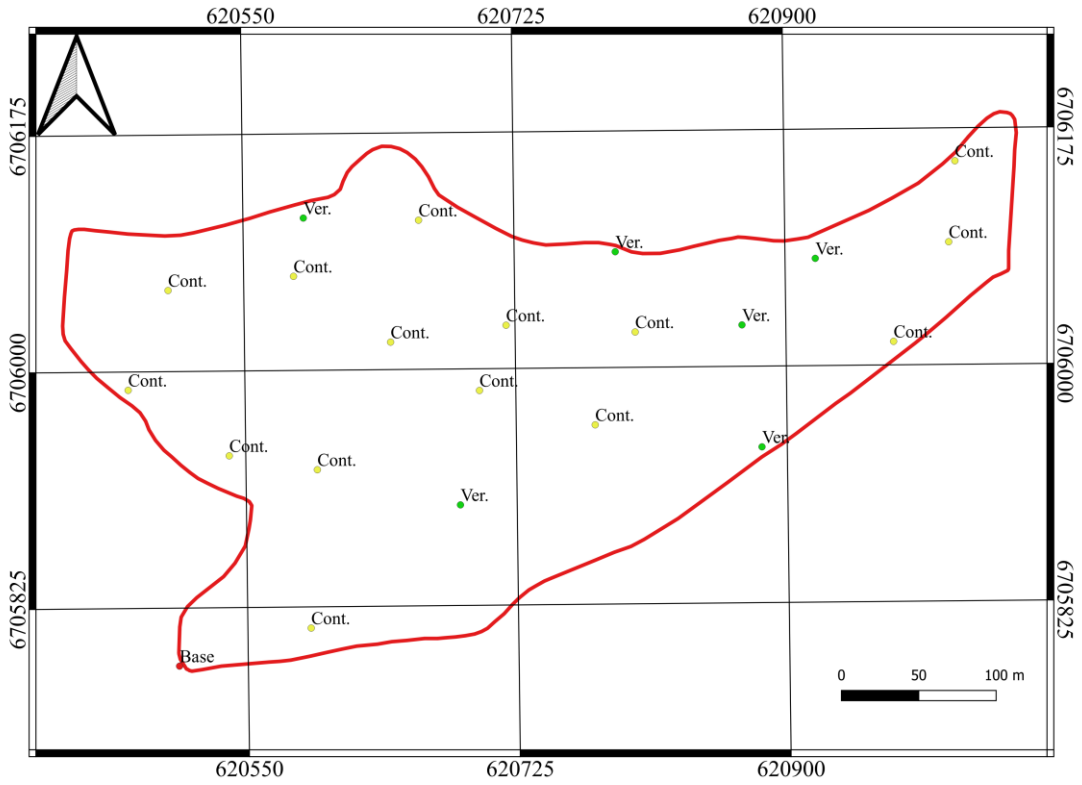


Figura 1. Vista aérea do talhão utilizado para a realização do trabalho, com a distribuição espacial dos pontos de controle (círculos em amarelo), de verificação (círculos em verde) e do ponto base (círculo vermelho).

Procedimento de coleta e análise envolvendo o uso de drone e correção em pós processamento cinemático (PPK)

Antes de iniciar o voo foi instalado o equipamento GNSS sobre o ponto base e logo em seguida FOI iniciada a coleta dos dados de posicionamento por ele (Figura 2a). O ponto base utilizado, foi o mesmo demarcado e utilizado na metodologia PC. Após o início da coleta no ponto base, iniciou-se o preparo do drone para o voo. Utilizou-se o drone marca modelo Nuvem UAV Spectral 2® (Figura 3b), equipado com um receptor GNSS extra (rover), frequência L1L2. Esse rover capta o erro de posição, durante sua trajetória, relativo a cada imagem, para fazer uma correção com base no instante de tomada da imagem durante o pós-processamento e assim georreferenciar cada imagem. O drone Spectral é equipado com uma câmera/sensor RGB Sony alfa 6000, para tomada das imagens.

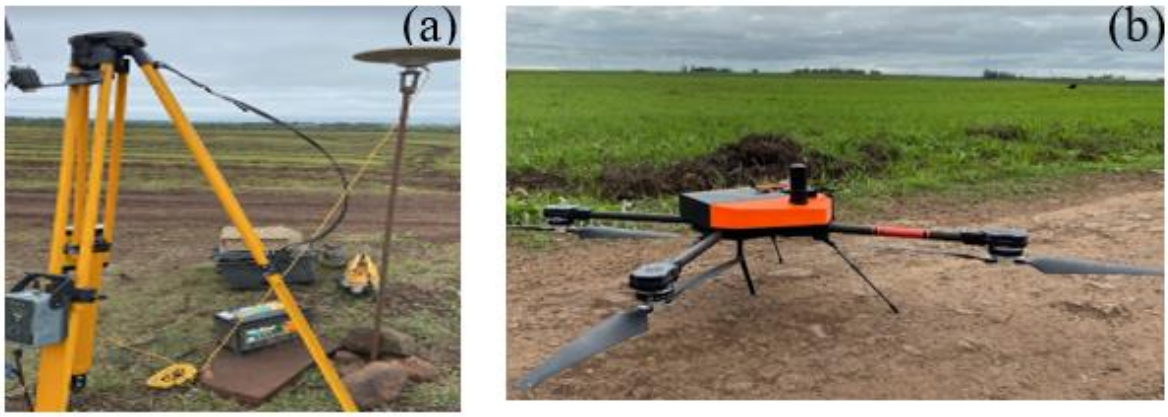


Figura 2. Drone Nuvem UAV Spectral 2® (a) e base utilizada para correção em pós processamento (b).

O plano de voo foi feito por meio do software N Control®, desenvolvido pelo próprio fabricante do drone Spectral. O voo foi realizado a uma altura de 287 metros com sobreposição, com 80% de sobreposição frontal e 80% de sobreposição lateral. Os equipamentos utilizados no ponto base, para a correção em pós processamento, foi um receptor GNSS ZPhiR-2 marca Trimble™, um rádio RTK TDL-450H um receptor de sinal Ag-542 marca Trimble™.

As imagens coletadas foram pós-processadas por meio do software RTKLIB®. Após a geração das geotags das imagens, essas foram então processadas no software WebODM™, para a criação do modelo digital de elevação, sendo que o que os dados altimétricos obtidos foram extraídos e trabalhados no software Quantum GIS ®.

Procedimento de coleta e análise envolvendo o uso de RTK embarcado em veículo automotivo (PPK)

A coleta de dados altimétricos nessa metodologia foi obtida embarcando o sistema RTK em uma camionete Strada, modelo Working, da marca Fiat®. O ferramental embarcado no veículo foi composto por um monitor da marca Trimble™, modelo XCN 2050, receptor GNSS modelo AG-25 da Marca Trimble™ com Rádio e sinal RTK (Figura 3). O sinal de correção RTK foi transmitido a partir de uma base RTK, fixada no mesmo ponto base utilizado nas metodologias PC e PPK. A base contava com um receptor GNSS ZPhir-2 marca Trimble™, um rádio RTK -DL450H e um receptor de sinal Ag-542 marca Trimble™.

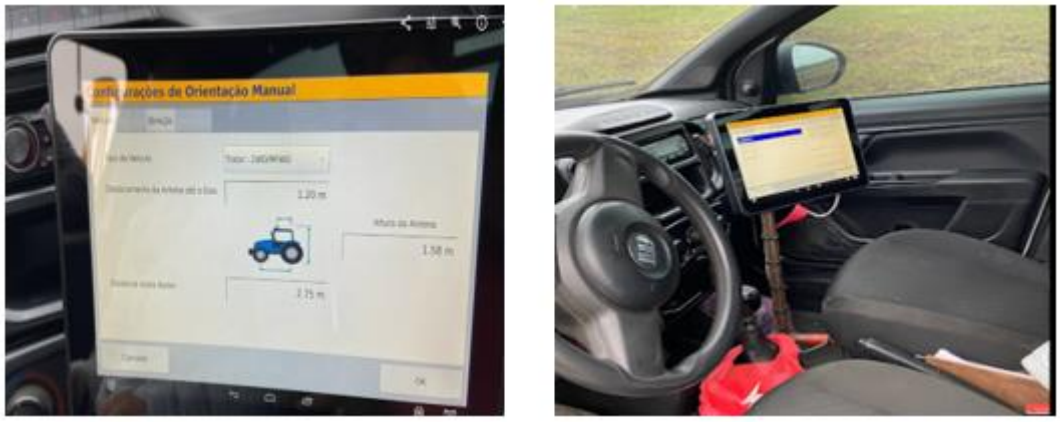


Figura 3. Detalhes do ferramental utilizado para coleta no interior do veículo.

Nessa metodologia, as elevações foram coletadas andando no terreno com a referida camionete, obedecendo um espaçamento entre as passadas de seis metros, e um ponto coletado a cada três metros de distância entre sai uma velocidade média de 15 km/h. Os dados oriundos do levantamento foram

descarregados para o computador e inicialmente processados no software Case IH AFS Software®, para conversão de formato proprietário para formato genérico, permitindo leitura dos dados no software Quantum GIS®. Os dados foram então interpolados para a geração do modelo digital de elevação e consequente extração das curvas de nível.

Detalhes sobre o processamento dos dados e geração dos Modelos Digitais de Elevação (MDE)

O MDE gerado pelas metodologias que envolvem drones (PC e PPK) foi obtido por meio do processamento digital das imagens aéreas obtidas. Inicialmente, as imagens foram pré-processadas utilizando o software Quantum GIS ®, de modo a excluir imagens que apresentaram nível de arrasto elevado. Essa análise foi realizada utilizando o plugin LF Tools, que opera dentro do Quantum GIS®. Feito o pré-processamento, as imagens obtidas foram processadas no software WebODM®, para geração do MDE.

O MDE obtido pela metodologia RTK também foi gerado utilizando o software Quantum GIS ®, sendo que os dados obtidos por meio dessa metodologia foram previamente convertidos em formato compatível com o referido software, por meio de outro software, denominado Case IH AFS Software®. Algumas etapas precederam a geração dos MDE gerado pelo RTK. Inicialmente foi realizado um pré-processamento dos dados, onde a primeira etapa do foi uma análise visual da nuvem de pontos gerada, utilizando o Quantum GIS ®, em busca de pontos eventualmente localizados de maneira muito discrepante, denotando erros na sua coleta. Em seguida, os dados foram analisados para verificar a presença de pontos onde a informação de elevação não foi gravada, assim como aqueles em que o parâmetro GpsHrms apresentou-se com valor maior que 1,5 centímetros. O parâmetro GpsHrms refere-se ao erro horizontal de posicionamento, no momento de gravação da informação. O erro vertical é aproximadamente 1,5 vezes o erro horizontal e é desejável que não seja superior a 2,5.

A última etapa do pré-processamento dos dados foi a filtragem do parâmetro elevação. Essa filtragem foi realizada conforme metodologia de MALDANER et al. (2022), utilizando a mediana para classificar um ponto dentro do banco de dados. A mediana foi tomada como parâmetro estatístico principal, e cada ponto medido teve sua filtragem avaliada pela discrepância em relação aos demais, em um raio de 5 metros. Essa filtragem foi realizada utilizando o software Mapfilter (MOLIN et al., 2019).

Finalizado o pré-processamento dos dados coletados pelo veículo automotivo equipado com RTK foram então interpolados utilizando o software Quantum GIS ®, para a geração do MDE e posteriormente o projeto de suavização.

Avaliação da similaridade entre os MDEs gerados

Para comparação dos MDEs obtidos, inicialmente foi gerada uma malha densa de pontos espaçados por 5 metros, utilizando o software Quantum GIS®. Através dessa camada de pontos foi possível extrair a informação de elevação de cada MDE, gerando uma camada/coluna para cada metodologia de levantamento dos dados. Com isso, foi realizada análise de estatística descritiva dos dados, representando-os por meio de um gráfico boxplot. Para tanto, criou-se duas variáveis resposta para comparação: elevação (metros acima do nível médios dos mares) e declividade (representada em %). Os dados de elevação e declividade do terreno foram submetidos a análise de correlação de Pearson e do coeficiente de determinação, utilizando o software R (R CORE TEAM, 2024).

Ainda, realizou-se uma análise de subtração das elevações geradas por cada metodologia, adotando como aceitáveis diferenças de até 10 centímetros (para mais ou para menos). Com isso, gerou-se um mapa de pontos com coloração verde, para as diferenças aceitáveis, e coloração vermelha para as diferenças não-aceitáveis. O valor de 10 centímetros se deu em função de que os perfis de taipas

utilizadas atualmente variando entre 10 e 15 centímetros de altura, adotando-se o menor valor desse intervalo.

A extração e análise das curvas de nível foi utilizada também como parâmetro de avaliação da similaridade entre as metodologias. As curvas de nível extraídas de cada MDE não foram suavizadas, procedimento usual que retira ângulos muito agudos e impossíveis de serem executados no campo. A partir das curvas extraídas obteve-se as seguintes variáveis resposta: comprimento máximo das curvas (metros), comprimento médio das curvas (m), comprimento mínimo das curvas (m), comprimento total das curvas (1000xm) e número total de curvas.

RESULTADOS E DISCUSSÃO

As três metodologias obtiveram uma elevação mínima muito próxima (~98m), indicando, inicialmente, serem similares. A elevação máxima variou um pouco mais, sendo PC a que registrou a maior elevação (103,13m) e RTK a menor (102,71m) (Figura 4). Essa diferença de 49 centímetros já é, na verdade, um indicativo de diferença entre os modelos de elevação. Em termos de distribuição dos dados (com base nos quartis), as metodologias apresentam valores semelhantes. O comportamento dos dados para a declividade demonstra comportamento semelhante ao observado para elevação, com as principais estatísticas descritivas sendo similares. Pode-se dizer que as maiores diferenças se deram quanto aos valores máximos de declividade, sendo que apenas o PPK apresentou valores próximos a 9% de declividade e os mais ficaram em torno de 8%.

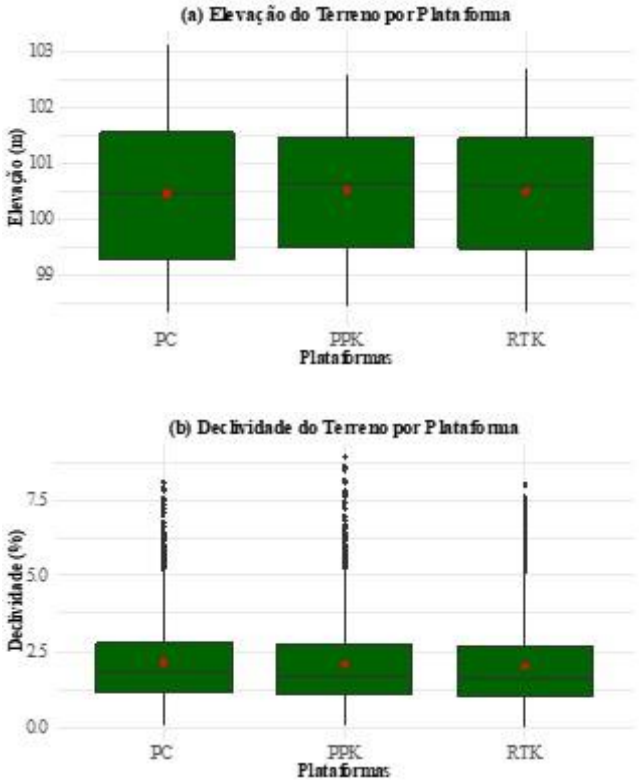
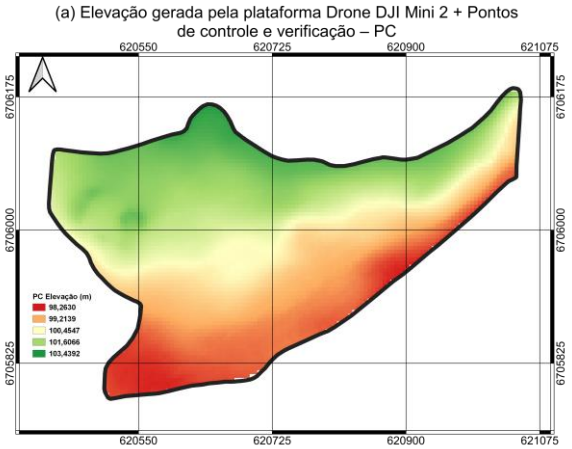
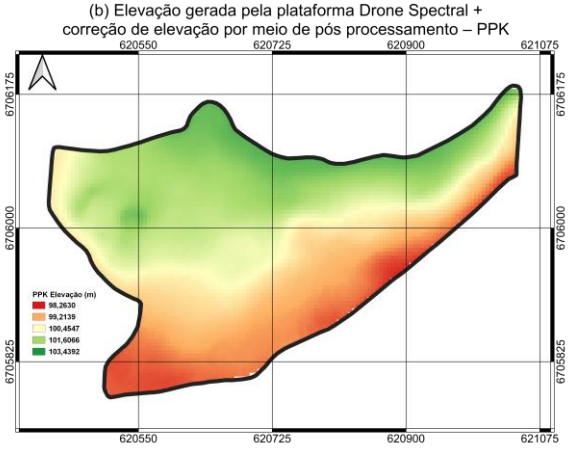


Figura 4. Estatística descritiva dos dados obtidos pelas diferentes metodologias para elevação (a) e declividade do terreno (%, b).

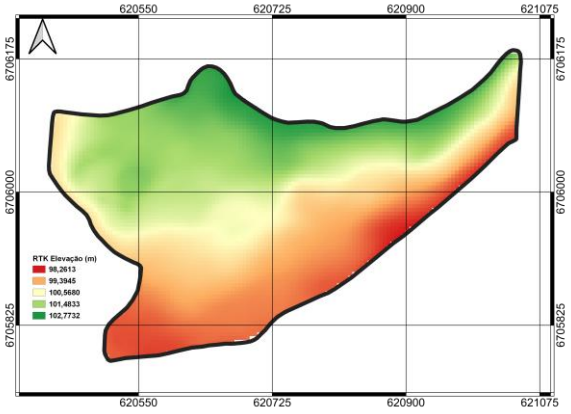
Em resumo, o boxplot indica que há uma boa similaridade entre as plataformas, quanto a elevação e declividade do terreno. No entanto, existem algumas diferenças, que podem impactar em função do nível de precisão exigido, especificamente, para um projeto de irrigação de arroz. Portanto, a escolha da plataforma pode variar dependendo do objetivo e critérios específicos.

As figuras contidas na Figura 5 representam a distribuição espacial da elevação e declividade gerada por cada uma das plataformas. A análise visual leva a intepretação de que os modelos são completamente equivalentes, em função de que a distribuição das duas variáveis ao longo dos MDE's é, de fato, similar. Porém, algumas diferenças podem ser observadas, por exemplo, na face noroeste do terreno, onde os modelos gerados por PPK e RTK mostram uma leve transição na elevação e na declividade do terreno, o que não acontece no MDE gerado por PC. Outro ponto importante a ser observado é uma transição mais suave entre as categorias de declividade no modelo gerado a partir de RTK, em relação aos demais. Isso demonstra um possível maior detalhamento do terreno quando o levantamento é feito com drones, independentemente do método. Porém, esse detalhamento não significa, necessariamente, maior precisão e acurácia no levantamento e pode dificultar o processamento das curvas de nível, demandando mais horas de trabalho e aumentando potenciais erros na geração das curvas (BUENO et al., 2019). Esse procedimento é conhecido como suavização das curvas, usualmente feito para permitir a execução por pilotos automáticos de modo que esses possam executar um projeto mantendo a trajetória planejada, sem desvios ou "desacionamentos" no campo (TAMIRAT et al., 2022).

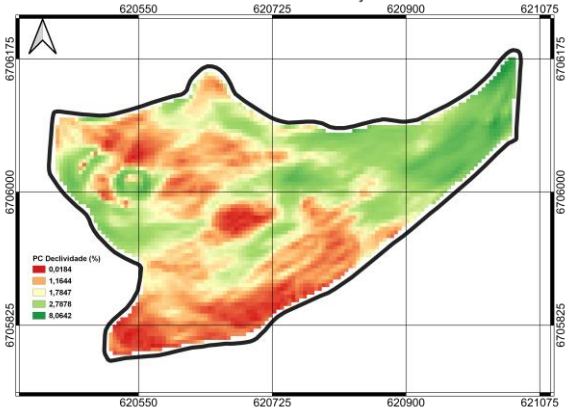




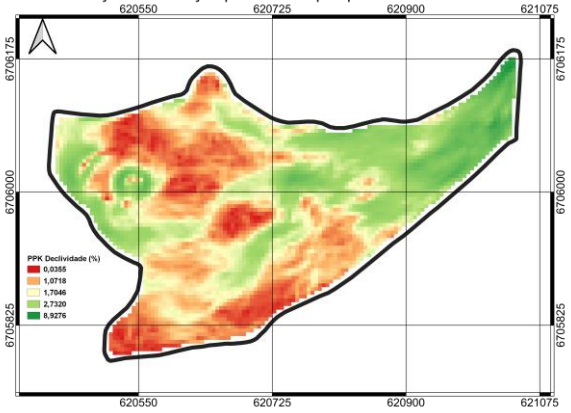
(c) Elevação gerada pela plataforma RTK embarcado em veículo automotivo – RTK



(d) Declividade gerada pela plataforma Drone DJI Mini 2 + Pontos de controle e verificação – PC



(e) Declividade gerada pela plataforma Drone Spectral + correção de elevação por meio de pós processamento – PPK



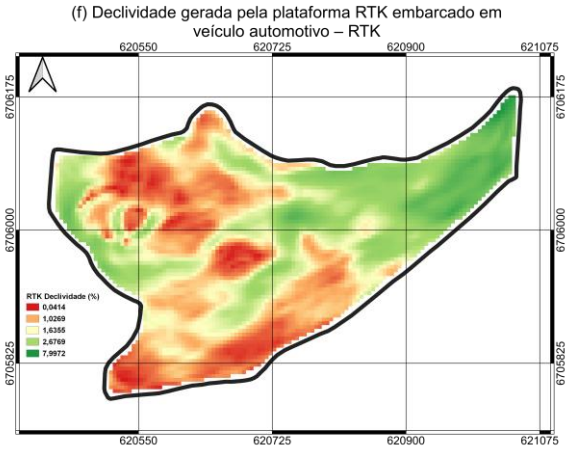
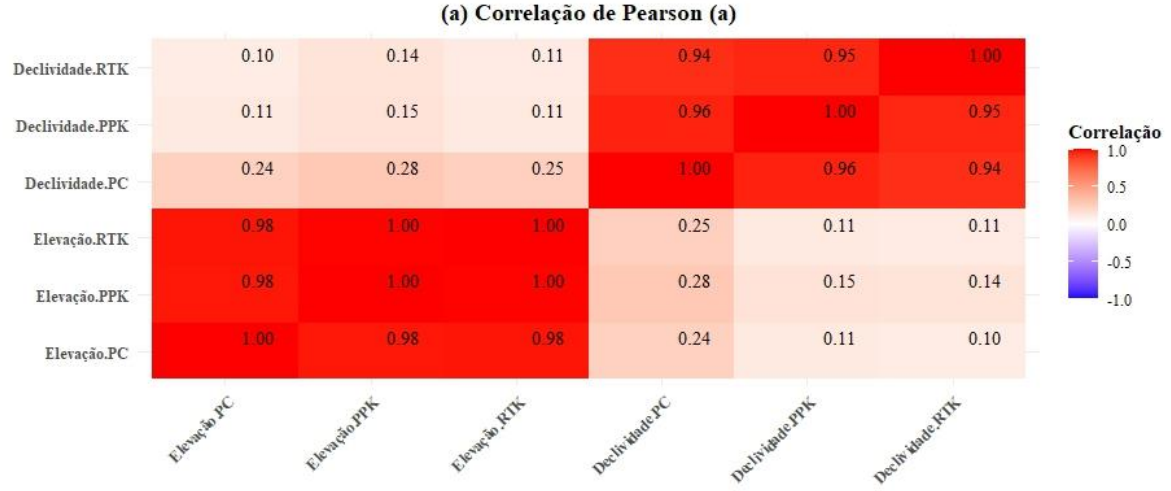


Figura 5. Representação geoespacializada dos valores de elevação (m) e declividade (%) gerados por cada uma das metodologias empregadas.

A Figura 6a apresenta o resultado da análise da correlação linear de Pearson, para elevação e declividade gerada para cada uma das metodologias. Observa-se, de maneira geral, altos valores de correlação entre todas as metodologias, para ambas as variáveis elevação e declividade do terreno. O nível de correlação de PC com PPK e RTK é de 0,98 para ambas as situações sendo, portanto, de quase 100%. Entretanto, esse nível de correlação é inferior ao nível de correlação observado entre PPK e RTK, que foi de 1,0. Desta forma, tem-se um indicativo de que, embora a metodologia PC tenha uma boa aproximação com RTK, o modelo gerado é inferior, em termos de similaridade, ao observado por PPK. Essa análise é confrontada e confirmada, por meio da relação linear entre as variáveis, onde embora ambas as metodologias tenham obtido valores altos de coeficiente de determinação, novamente o desempenho do PPK foi superior e mais próximo de RTK do que PC (Figura 6b e 6c). Ainda quanto a correlação de Pearson, comportamento similar é observado para a declividade, uma vez que essa variável é um produto obtido a partir das diferenças de elevação do terreno, tendo uma leve diferença quanto aos valores obtidos nas correlações.



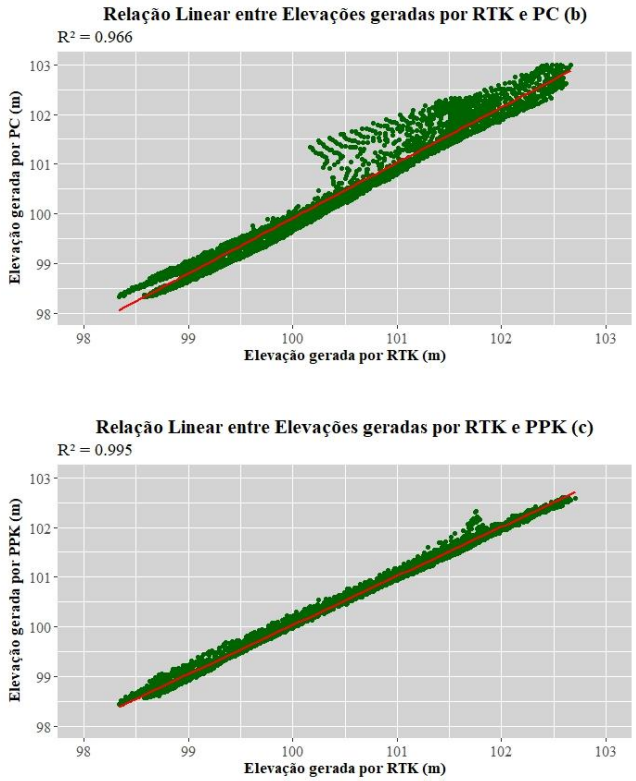
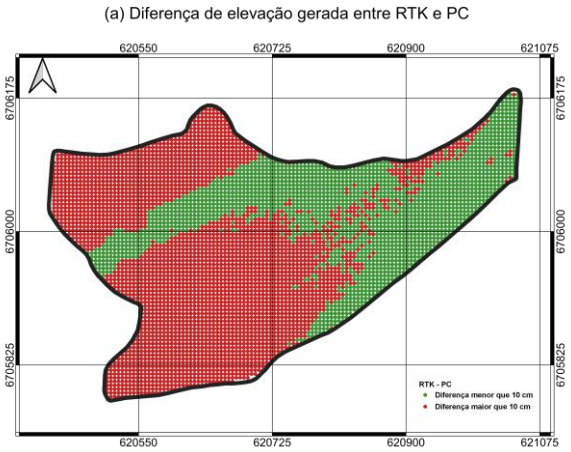


Figura 6. Correlação Linear de Pearson entre os modelos gerados pelas diferentes plataformas de aquisição de dados.

Até esse momento do texto, todas as análises realizadas levam a um entendimento de que as três metodologias apresentam resultados muito similares, com pequena desvantagem para a metodologia PC, ou seja, assim como BUENO et al. (2019), é possível encontrar um método mais eficaz na geração de curvas de nível para o arroz. Porém, a Figura 7 evidencia de forma mais contundente as diferenças entre os MDEs. Atualmente, o perfil das taipas ou diques construídos no local demarcado para as curvas de nível varia entre 10-15 cm, sendo comum alturas de 12 a 13 centímetros (BEUTLER et al., 2012), com objetivo de fazer uso mais eficiente da água. A Figura 7 representa, com pontos vermelhos, locais com diferença entre as elevações obtidas por cada metodologia é maior que 10 cm (para mais ou para menos), e pontos verdes representam diferenças menores que 10 cm, assumindo ser problemático considerar o limite de altura médio das taipas para visualizar as diferenças.



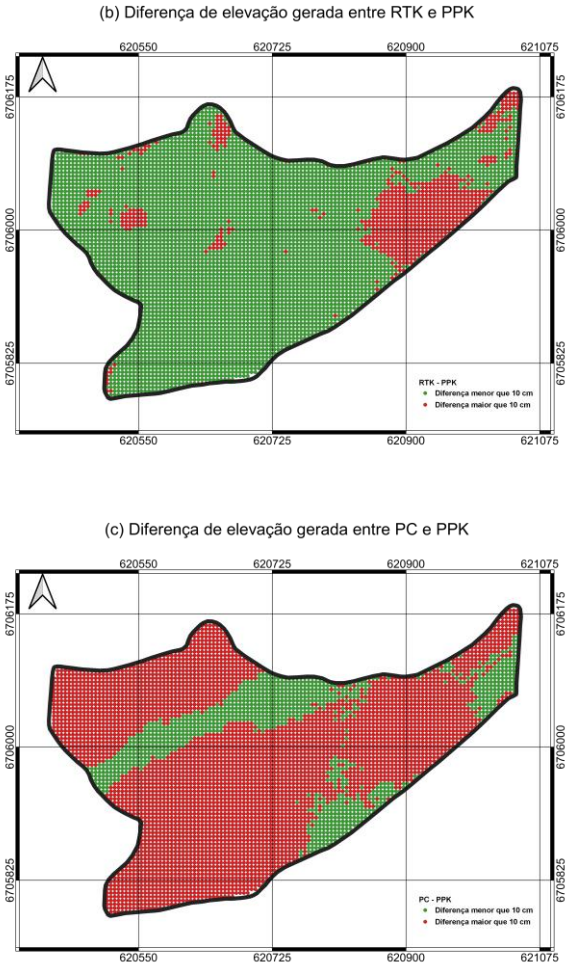


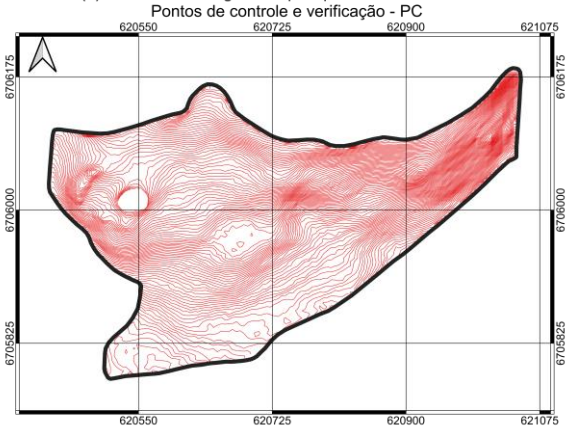
Figura 7. Representação da distribuição de pontos com diferença de elevação maior ou menor que 10 centímetros entre os modelos gerados por cada plataforma de aquisição.

Podemos observar que o mapa, da Figura 7b, apresenta um maior número de pontos verdes é justamente o que ilustra as diferenças de elevação entre PPK e RTK. Importante observar, utilizando como "fundo" os mapas de declividade, que a maior concentração de pontos vermelhos é onde se observa valores mais elevados de declividade. Esse comentário é importante em função de que o maior impacto do erro de nivelamento e geração das curvas se dá nas menores declividades, em função de que o número de curvas é menor e a área entre curvas é grande, podendo gerar grandes área com lâmina d'água inexistente. Nas partes mais declivosas do terreno, usualmente se utiliza número maior de curvas e, embora se torne mais trabalhoso operacionalmente, o problema de falta de água entre as taipas é reduzido. O que se observa é que PC (Figura 7b), além de ter um número maior de pontos com diferença acima de 10 cm, concentrou grande parte das diferenças nas áreas com declividade inferior a 1%. Com isso, é esperado que haja, principalmente mudança no sentido das curvas geradas por PC, em relação as curvas geradas por RTK. Ainda, as curvas geradas por PPK deverão estar dispostas em um sentido similar ao RTK.

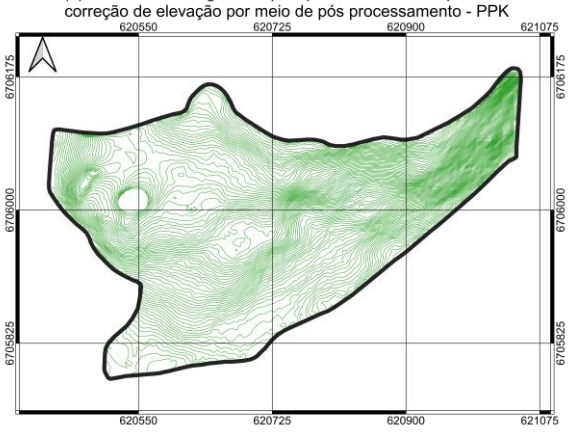
A Figura 8 representa a distribuição das curvas no terreno, de acordo com cada metodologia, assim como as métricas relacionadas a comprimento e número de curvas. Conforme comentado e esperado após análise da Figura 7, de fato observa-se que PC apresentou curvas com sentido diferente (Figura 8a), em relação a RTK (Figura 8c), em zonas do talhão com menores declividades, podendo assim trazer problemas na irrigação do cultivo (NARESH et al., 2014). Como também era esperado, após análise da Figura 7, PC apresentou sentido das curvas muito similar ao RTK em zonas com declividade mais acentuada e assim, nessas situações, o uso dessa metodologia não impactaria a

irrigação. O mesmo não é observado para PPK, que apresentou curvas com sentido similar ao RTK em quase todo o terreno, tanto em zonas de menor e maior declividade (Figura 8b).

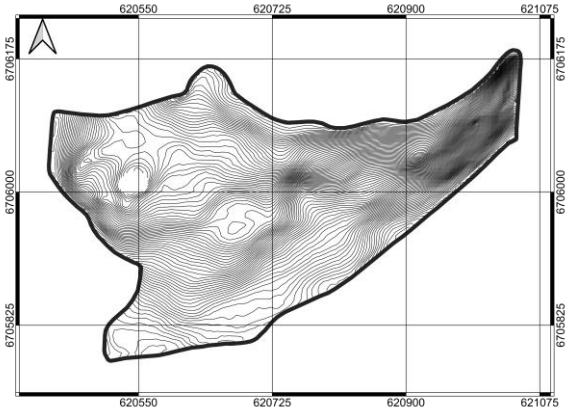
(a) Curvas de nível geradas pela plataforma DJI Mini 2 + Pontos de controle e verificação - PC



(b) Curvas de nível geradas pela plataforma Drone spectral + correção de elevação por meio de pós processamento - PPK



(c) Curvas de nível geradas pela plataforma RTK embarcado em veículo automotivo - RTK



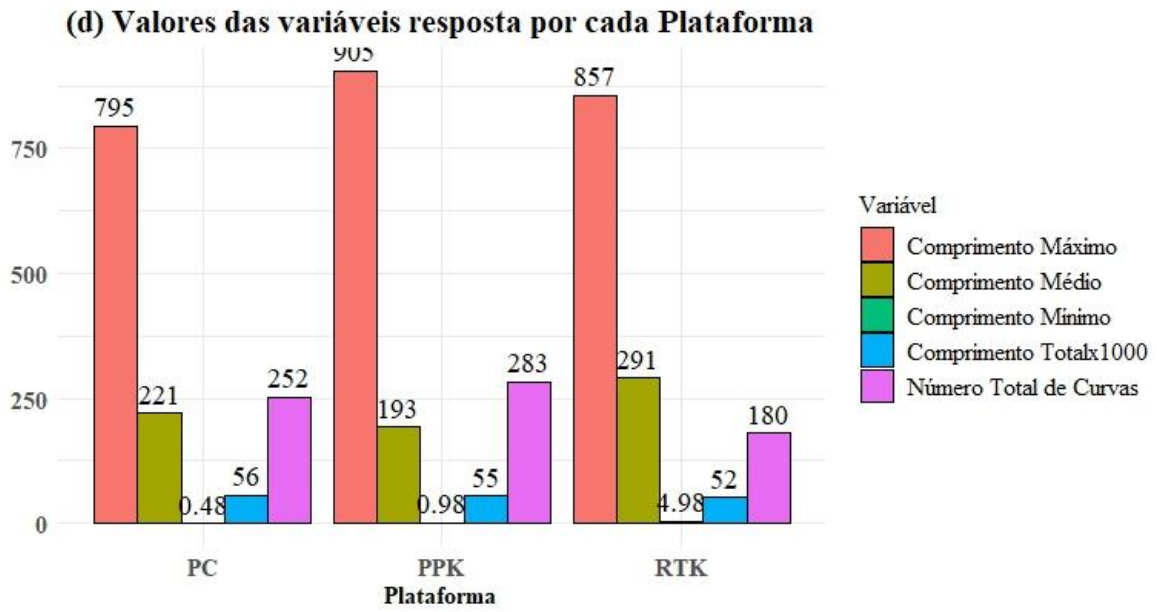


Figura 8. Análise descritiva das curvas de nível geradas a partir de cada plataforma de aquisição de dados.

Também se observou diferença em métricas relacionadas ao comprimento das curvas, assim como no número total de curvas de cada metodologia. O ideal é que as diferenças fossem pequenas, pois métricas como o número total de curvas ou mesmo o comprimento médio das curvas impacta em termos operacionais, sendo ideal cobrir o talhão com o menor número de curvas, mantendo qualidade da irrigação. Isso, conforme relatado por BUENO et al. (2019), é conseguido quando se adquire os dados de elevação por meio de RTK embarcado em veículos como trator. Porém, apesar do já mencionado sobre o sentido das curvas, ambas as metodologias PC e PPK apresentaram métricas que as diferenciam do RTK, sendo essa diferença uma potencial desvantagem. Por exemplo, utilizando RTK seria necessário um percurso equivalente a 52,484 mil metros, enquanto com PPK o percurso seria de 54,756 mil metros e 55,669 mil metros. A que se considerar ainda que os maiores percursos gerados por PPK e PC iriam aumentar tempo o número de manobras de cabeceira, já que o número total de curvas seria de 283 e 252, respectivamente.

Convém lembrar que optamos, em nosso estudo, por não realizar o processo de suavização das curvas (NARESH et al., 2014), que pode diminuir o comprimento total das curvas, assim como permite que o analista exclua segmentos pequenos ou mesmo adicione novos, como uma prática comum no campo, de criar "taipas loucas". Entende-se que o processo de suavização é muito sensível ao analista que desenha o projeto, sendo esse o motivo de excluir essa variável de nosso comparativo. Falando especificamente a respeito de segmentos curtos, esse é outro ponto que diferencia PPK e PC de RTK. Os comprimentos mínimos de curvas foram de 0,98 m e 0,48 m, para PPK e PC, respectivamente, enquanto para RTK o segmento mais curto foi de 4,8 m. Pode-se dizer que 4,8 m é um segmento de curva ainda curto, mas passível de ser utilizado, principalmente em entradas de zonas com maior elevação. Essa diferença retrata o maior detalhamento do terreno que é feito em levantamentos com drone, sendo comum pixels na casa dos centímetros (COELHO et al., 2018; HAMANN, 2018; AMARAL et al., 2020). Esse detalhamento funciona muito bem para aplicações especificas de monitoramento da vegetação, mas não necessariamente seja um grande facilitador quando deseja-se captar as elevações do terreno. O maior problema que esse detalhamento pode causar é durante o processamento das curvas, demandando do analista maior experiência para tomada de decisão a respeito do que suavizar, do que excluir e do que adicionar, para manter o nível de qualidade em projetos feitos com drone.

Contudo, os resultados colocam a metodologia PPK, ou seja, tendo drone como plataforma de aquisição de dados altimétricos, tendo um bom potencial para ser utilizado em conjunto ou em

substituição ao RTK. Entretanto, é importante a realização de um trabalho de cunho econômico, uma vez que ambas as metodologias apresentam diferenças substanciais no campo operacional. O levantamento dos dados por plataformas como os drones ganha muito em escala de tempo em campo, podendo iniciar antes a coleta de dados após uma chuva, por exemplo. Entretanto, a capacidade de processamento de um computador e o tempo para gerar o MDE é maior. Por fim, a execução do projeto mostrou-se ser potencialmente mais rápida com RTK. Em seu trabalho, HAMANN (2023) fez uma análise de custos relacionada a implantação de curvas de nível/taipas utilizando drones em comparação a utilização de nível laser, método que ainda é amplamente utilizado, mas que conforme BUENO et al. (2019), é inferior ao RTK. O trabalho de HAMANN (2023) observou que o custo do uso de drones frente ao uso do nível laser é de até 95%.

Porém, ainda não se tem na literatura essa análise comparando as mesmas metodologias utilizadas neste trabalho. Deve-se mencionar também que um estudo econômico completo precisa considerar também qual a produtividade obtida pelo arroz irrigado e todos os custos associados, principalmente aqueles relacionados ao uso da água. O custo do projeto em si pode ser menor, mas não pode prejudicar a produtividade, a rentabilidade e a sustentabilidade (uso da água) da cultura.

Cabe mencionar que a metodologia PC é de difícil implementação em larga escala no campo, pois além de ter apresentado diferenças importantes frente ao RTK, o processo de coleta de pontos de controle e verificação consome certa quantia de tempo. Como a metodologia PPK não necessitou de uso de pontos de controle para atingir resultado similar ao RTK, é provável que o uso de PC fique restrito a situações de áreas com declividade acima de 1% e que o tamanho da área a ser levantada seja pequeno.

CONCLUSÃO

Drones embarcados com tecnologia PPK podem ser utilizados para demarcação de curvas de nível em arroz irrigado, mantendo padrão similar a projetos gerados por RTK embarcado em veículos automotivos. Drones que necessitam de correção de posicionamento por meio de pontos de controle e verificação tem seu uso mais restrito, pois apresentaram sentido de curvas diferentes em zonas com declividade inferior a 1%, podendo serem utilizados apenas em situações com declividade superior.

AGRADECIMENTOS

Ao produtor de arroz Marco Antonio Raffin Ancinelo, pela cedência da área e demais estruturas para realização dos levantamentos e condução do trabalho.

A empresa Agroser, representante da marca Case IH para a Fronteira Oeste e Campanha do RS, pela disponibilização do ferramental utilizado nas metodologias PPK e RTK.

REFERÊNCIAS

AMARAL, L. R.; ZERBATO, C.; FREITAS, R. G.; BARBOSA JÚNIOR, M. R.; SIMÕES, I. O. P. S. UAV applications in Agriculture 4.0. **Revista Ciência Agronômica**, v. 51, Special Agriculture 4.0, e20207748, 2020.

BEUTLER, A. N.; MUNARETO, J. D.; RAMÃO, C. J.; GALON, L.; DIAS, N. P.; POZZEBON, B. C.; RODRIGUES, L. A. T.; MUNARETO, G. S.; GIACOMELI, R.; RAMOS, P. V. Propriedades físicas do solo e produtividade de arroz irrigado em diferentes sistemas de manejo. **Revista Brasileira e Ciência do Solo**, v. 36, p. 1601-1607, 2012.

BUENO, M. V.; CAMPOS, A. D. S.; SILVA J. T.; FARIAS, L. C.; TERRA, F. S.; PARFITT, JOSÉ M. B. Demarcation of Levees in Irrigated Rice Fields: Laser Technology vs. GNSS-RTK. **Applied Engineering in Agriculture**, v. 35, p. 431-437, 2019.

COELHO, R. C.; SILVA, R. L.; COSTA, R. S. S. Mapeamento topográfico, com utilização de veículo aéreo não tripulado (VANT) e topografia convencional. **In: II Simpósio Internacional de Águas, Solos e Geotecnologias (SASGEO) III, 2018, Vila Real - Portugal. II Simpósio Internacional de Águas, Solos e Geotecnologias (SASGEO) III JORNADAS INTERACT**. Vila Real: Minerva Transmontana, Tipografia, Lda. Vila Real, 2018. p. 203-206.

IRGA - Instituto Rio Grandense do Arroz. **Boletim de resultados da safra 2022/23 em terras baixas: arroz irrigado e soja e milho em rotação**. Porto Alegre, RS, 2023. 22 p. Disponível em: < https://admin.irga.rs.gov.br/upload/arquivos/202308/23105302-boletim-de-resultados.pdf >. Acesso em 20 mar. 2024.

HAMANN, P. O. **Viabilidade operacional e econômica da utilização de vants e ferramentas digitais para a demarcação de taipas em lavoura de arroz irrigado**. 2023. 66 p. Trabalho de Conclusão de Curso, Universidade Federal do Pampa, Itaqui, 2023.

MALDANER, L. F.; MOLIN, J. P.; SPEKKEN, M. Methodology to filter out outliers in high spatial density data to improve maps reliability. **Scientia Agricola**, v. 79, n. 1, e20200178, 2022.

MOLIN, J. P.; SPEKKEN, M; MALDANER, L. F. **MAPFILTER 2.0**. 2019. Patente: Programa de Computador. Número do registro: BR512019002014-6, data de 21/08/2022.

NARESH, R. K., SINGH, S. P., MISRA, A. K., TOMAR, S. S., KUMAR, P., KUMAR, V. & KUMAR, S. Evaluation of the laser levelled land leveling technology on crop yield and water use productivity in Waster Uttar Pradesh. **African Journal of Agricultural Research**, v. 9, n. 4, p. 473-478, 2014.

R CORE TEAM (2024). _R: A Language and Environment for Statistical Computing. **R Foundation for Statistical Computing**, Vienna, Austria. <https://www.R-project.org/>.

SILVA, D. A. A.; BRUTTI, M. A.; PIAZ, O. H.; BERGHETTI, J.; SANTI, A. L. SISTEMA JOHN DEERE - SURFACE WATER PROTM E CR - CAMPEIRO 7 PARA OBTENÇÃO DE DADOS ALTIMÉTRICOS NO MANEJO DO ARROZ IRRIGADO. In: **Congresso Brasileiro de Agricultura de Precisão**, 2014, São Pedro/SP. Congresso Brasileiro de Agricultura de Precisão-ConBAP 2014, 2014.

SOSBAI - Sociedade Sul-Brasileira de Arroz Irrigado. **Arroz Irrigado: Recomendações técnicas da pesquisa para o Sul do Brasil**. Restinga Seca, RS, 2022. 200 p. Disponível em: <https://www.sosbai.com.br/uploads/documentos/recomendacoes-tecnicas-da-pesquisa-para-o-sul-do-brasil_310.pdf>. Acesso em 20 mar. 2024.

TAMIRAT, T. W.; PEDERSEN, S. M.; FARQUHARSON, R. J.; BRUIN, S.; FORRISTAL, P. D.; SØRENSEN, C. G.; NUYTTENSF, D.; PEDERSEN, H. H.; THOMSEN, M. N. Controlled traffic farming and field traffic management: Perceptions of farmers groups from Northern and Western European countries. **Soil & Tillage Research**, v. 217, 105288, 2022.

MODELOS LOCAIS DE SENSORES XRF PARA PREDIÇÃO DE NUTRIENTES DISPONÍVEIS POSSUEM ESTABILIDADE TEMPORAL?

Gabriel Toledo Marques [1]; Tiago Rodrigues Tavares [3]; Marcos Mantelli Ragagnin [1]; Jose Paulo Molin [2]; Hudson W P de Carvalho [4]

[1]Estudante de Graduação. Avenida Pádua Dias, 11, 13418-900, Piracicaba, São Paulo, Brasil. Universidade de São Paulo - Escola Superior de Agricultura 'Luiz de Queiroz; [2]Professor. Avenida Pádua Dias, 11, 13418-900, Piracicaba, São Paulo, Brasil. Universidade de São Paulo - Escola Superior de Agricultura 'Luiz de Queiroz; [3]Pesquisador Pós-Doc. Av. Centenário, 303 - São Dimas CEP: 13416-000 - Piracicaba (SP) - Brasil +55 19. 3429 4611. Universidade de São Paulo - Centro de Energia Nuclear na Agricultura; [4]Professor. Av. Centenário, 303 - São Dimas CEP: 13416-000 - Piracicaba (SP) - Brasil +55 19. 3429 4611. Universidade de São Paulo - Centro de Energia Nuclear na Agricultura; [5]Professor. Av. Centenário, 303 - São Dimas CEP: 13416-000 - Piracicaba (SP) - Brasil +55 19. 3429 4611. Universidade de São Paulo - Centro de Energia Nuclear na Agricultura

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

As técnicas de sensoriamento permitem o monitoramento da fertilidade dos solos de forma prática, limpa e em larga escala, fator essencial para superar o gargalo de produtividade atual. Sensores de espectroscopia de fluorescência de raio-x (XRF) são ferramentas versáteis para o estudo da fertilidade do solo, por apresentar bom desempenho para a predição dos nutrientes disponíveis, e.g., ex-Ca, ex-K. Porem existem dúvidas sobre as variáveis que afetam esta técnica, como o desempenho de um mesmo modelo para diferentes anos. Assim, objetivou avaliar a estabilidade temporal do desempenho preditivo de um modelo de XRF para ex-Ca e ex-K ao ser calibrado em um ano (2015) e extrapolado para amostras coletadas em anos subsequentes (2019, 2020, e 2022) e avaliar o impacto no modelo ao aplicar calcário e pó de rocha. Para os anos de 2015, 2019 e 2020 tanto RMSE quanto Bias foram estáveis (RMSE variando entre anos 1,48 e 0,56 $mmol_c dm^{-3}$ para ex- Ca e ex-K respectivamente e para Bias de 5,51 para ex-Ca e 2,13 para ex-K), para a primeira amostragem de 2022 (pós aplicação) teve um RMSE de 40,64 e 6,37 $mmol_c dm^{-3}$ para ex-Ca e ex-K respectivamente e um Bias de 16,78 e 2,97 para ex-Ca e ex-K, valores que reduziram para as amostragens seguintes. Concluiu-se que o desempenho se manteve estável para 2019 e 2020 e alterou em 2022 devido a aplicação de calcário e pó de rocha retornando a normalidade com o passar do tempo pós aplicação.

PALAVRAS-CHAVE: Sensoriamento; Fertilidade do solo; Modelagem

ABSTRACT

Sensing techniques allow soil fertility to be monitored practically, cleanly and on a large scale, which is essential for overcoming the current productivity bottleneck. X-ray fluorescence spectroscopy (XRF) sensors are versatile tools for studying soil fertility, as they perform well in predicting available nutrients, e.g. ex-Ca, ex-K. However, there are doubts about the variables that affect this technique, such as the performance of the same model for different years. Thus, the aim was to evaluate the temporal stability of the predictive performance of an XRF model for ex-Ca and ex-K when calibrated in one year (2015) and extrapolated to samples collected in subsequent years (2019, 2020, and 2022) and to evaluate the impact on the model when applied limestone and rock dust. For the years 2015, 2019 and 2020 both RMSE and Bias were stable (RMSE varying between years 1.48 and 0.56 $mmol_c dm^{-3}$ for ex-Ca and ex-K respectively and Bias of 5.51 for ex-Ca and 2.13 for ex-K), for the first sample in 2022 (post-application) it had an RMSE of 40.64 and 6.37 $mmol_c dm^{-3}$ for ex-Ca and ex-K respectively and a Bias of 16.78 and 2.97 for ex-Ca and ex-K, values that decreased for the following samples. It was concluded that performance remained stable for 2019 and 2020 and

changed in 2022 due to the application of limestone and rock dust, returning to normal over time after application.

KEYWORDS: ;

INTRODUÇÃO

Sensores de fluorescência de raios X (XRF) permitem análises de amostras de solo de maneira rápida (e.g., 30 a 90s por amostra) e sem uso de reagentes, obtendo informações sobre sua constituição elementar (WEINDORF; CHAKRABORTY, 2020). Dados de XRF estão sendo utilizados para inferir sobre atributos de fertilidade, tanto em solos de regiões tropicais (ANDRADE et al., 2020), quanto de clima temperado (NAWAR et al., 2019). De maneira geral, trabalhos em regiões tropicais tem demonstrado bons desempenhos (e.g., $R^2 \geq 0,70$) para predição de textura (ANDRADE et al., 2020), nutrientes extraíveis (e.g., ex-Ca, ex-K e ex-Mg) (TEIXEIRA et al., 2018) e atributos químicos (e.g., saturação de bases (V%), capacidade de troca catiônica (CTC), etc) (SILVA et al., 2017). Em solos tropicais, Tavares et al. (2020a e 2021) apresentou $R^2 > 0,84$ para ex-Ca, ex-Mg, ex-K, CTC e V%. Por sua vez, Kaniu et al. (2012) um $R^2 > 0,92$ para ex-Mg e ex-K em solos tropicais africanos. A capacidade de análise da fertilidade do solo sem necessidade de procedimentos de via úmida (e.g., digestão e extração) faz do XRF um equipamento promissor para compor laboratórios híbridos e/ou laboratórios móveis, ou seja, ambientes de análise menos complexos que laboratórios tradicionais que evitam o uso excessivo de reagentes e que podem viabilizar análises de forma easy-to-use (MOLIN; TAVARES, 2019). Contudo, para que isso seja possível é necessário entender como se dá a estabilidade temporal do desempenho preditivo do XRF ao avaliar uma mesma área em vários anos (RIEBE ET AL., 2019; TAVARES ET AL., 2020a). Por exemplo, modelos preditivos calibrados em um ano podem ser extrapolados para amostras coletadas no ano seguinte? Se houver a aplicação de insumos (e.g., pó de rocha e calcário), os quais possivelmente vão alterar a relação entre teores totais e disponíveis de nutrientes, os desempenhos preditivos do XRF ainda permanecerão satisfatórios?

OBJETIVOS

Visando os pontos acima, este trabalho teve como objetivo avaliar se o desempenho preditivo de modelos XRF para ex-Ca e ex-K possuem estabilidade temporal e se a alteração do manejo, neste caso a aplicação de calcário e pó de rocha, teria impacto no desempenho preditivo dos modelos.

MATERIAL E MÉTODOS

O trabalho foi conduzido em um talhão agrícola localizado no município de Piracicaba - SP. O período de estudo para este trabalho compreende do ano de 2015 até 2022, passando por diferentes ciclos produtivos e manejos de solo realizados na área somado a uma aplicação de diferentes doses de calcário e pó de rocha (tabela 1) no início do ano de 2022 para indução da alteração da relação entre Ca total e ex-Ca, assim como K total e ex-K. As amostras foram coletadas sempre em dois conjuntos de seis parcelas cada, totalizando 12 parcelas (figura 1). Os pontos foram coletados com receptor GNSS-RTK, com precisão submétrica, para permitir voltar na mesma área nos anos seguintes.

Tabela 1. Dosagens de calcário e pó de rocha aplicadas

Parcela	Conjunto de parcelas 1	Conjunto de parcelas 2
	CaO	K_2O
T1	300	50

T2	900	150
T3	1500	250
T4	2100	350
T5	2700	450
T6	0	0

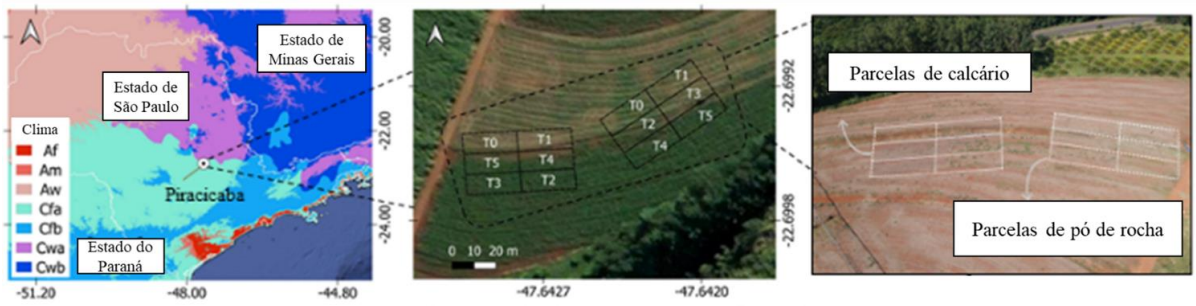


Figura 1. Divisão da área de estudo

Foram realizadas 6 coletas de solo entre os anos de 2015 e 2022 (figura 2). As amostragens foram designadas como S15 (1ª coleta) realizada em 2015, S19 (2ª coleta) em 2019, S20 (3ª coleta) em 2020, S22a - S22b - S22c (4ª, 5ª e 6ª coleta respectivamente) realizadas em 2022 após a aplicação de calcário e pó de rocha com uma diferença de 3 meses entre cada coleta de 2022. As amostras coletadas foram secas, peneiradas (< 2mm) e armazenadas em local coberto e arejado da maneira descrita por Tavares et al (2020a). Todas as amostras foram analisadas com o XRF. Para isso, aproximadamente 10 gramas foram alocados em uma cubeta de polietileno com fundo selado com filme de polipropileno de 4 µm de espessura (SPEX, Metuchen, NJ, USA) para que não ocorra interferência na coleta. As coletas foram feitas em duplicata alterando a posição da cubeta no sensor durante cada coleta. Foi utilizado um XRF portátil (Tracer-III-SD, Bruker AXS, Madison, WI, EUA), o qual foi configurado conforme as condições instrumentais sugeridas por Tavares et al., (2020a). Usou-se tensão e corrente do tubo em 35kV e 7µA, tempo de coleta de 30s e análises conduzidas em pressão atmosférica (i.e., sem vácuo), sem a utilização de filtros. Os espectros adquiridos foram normalizados pelo tempo de operação do detector (live time). Foram utilizadas doze linhas de emissão como variáveis independentes, sendo elas as linhas Kα de Al, Si, K, Ca, Ti, Mn, Fe, Ni e Cu, e de espalhamento Rh-Lα Thomson, Rh-Kα Compton e Rh-Kα Thomson. Exceto as linhas de espalhamento, todas as linhas foram normalizadas pela intensidade de radiação Rh Kα Compton (TAVARES et al., 2020b). Após as análises com XRF, as amostras foram enviadas a um laboratório comercial para a análise por via úmida para determinação dos teores de ex-Ca, ex-K. As análises seguiram os métodos descritos por Gianello e Amorim (2015) sendo os nutrientes (ex-Ca, ex-K) extraídos por NH_4CL 1 $mol.L^{-1}$ e quantificados via espectroscopia de emissão atômica por plasma acoplado indutivamente (ICP-OES).

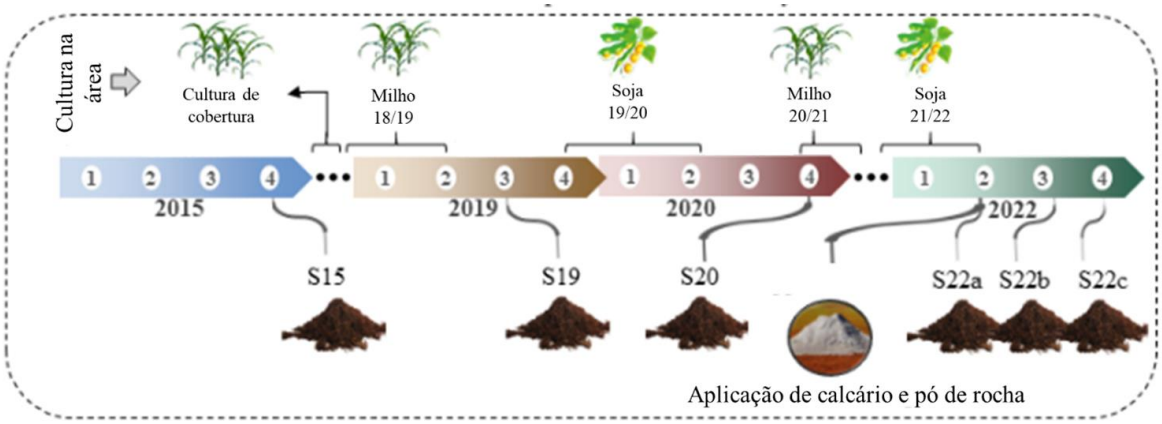


Figura 2. Representação do histórico da área durante no período de 2015-2022

A variação do teor total de Ca e K ao longo das diferentes amostragens foi realizada monitorando a intensidade da emissão das linhas Ca-Kα e K-Kα, respectivamente. O monitoramento dos teores totais em termos relativos por meio da intensidade de emissão de fluorescência de raios X é um método de determinação mais efetivo que métodos de química úmida, os quais comumente obtém digestões incompletas de amostras de solo e subestimam os teores totais de elementos presentes em estruturas minerais de difícil digestão (WEINDORF AND CHAKRABORTY, 2020). Além disso, este estudo utiliza amostras locais, coletadas em uma área de 0,30 ha, o que permite desconsiderar o efeito matriz nos dados XRF. Em relação a modelagem de dados, modelos de regressão linear múltipla foram calibrados para ex-Ca e ex-K com a amostragem S15 e, em seguida, extrapolados nas amostras referentes às amostragens S19, S20, S22a, S22b e S22c. Os valores preditos pelos modelos foram comparados com os valores obtidos via úmida. O desempenho foi avaliado com a análise da raiz quadrada do erro-médio (RMSE) e do desvio sistemático no erro (Bias). Por fim, o desempenho obtido em cada amostragem foi comparado com as relações entre teores totais e disponíveis de nutrientes. Esta análise permitiu avaliar a estabilidade temporal do desempenho do sensor XRF, assim como verificar se o manejo da adubação com calcário e pó de rocha potássica tem influência em seu desempenho.

RESULTADOS E DISCUSSÃO

As linhas de emissão Ca-Kα e K-Kα dos espectros XRF, representadas em contagem de fótons por segundo (cps), estão diretamente relacionadas aos teores totais destes elementos nas amostras de solo estudadas. A Figura 2 compara essas linhas de emissão com os teores disponíveis de cada nutrientes. Observa-se que a aplicação do calcário e pó de rocha aumentou expressivamente a concentração dos teores totais das amostras obtidas em S22a, S22b e S22c (figura 3 B e D). Por exemplo, Ca-Kα em S15, S19 e S20 apresentou uma amplitude de variação de 75 a 193 cps, enquanto para S22a, S22b e S22c, esse valor variou de 75 a 750 cps. Já na linha K-Kα, em S15, S19 e S20, os valores ficaram entre 16 e 48 cps, por sua vez para S22a, S22b e S22c, variou de 22 a 132 cps. Um aumento nos teores disponíveis pode ser notado, principalmente para o Ca. Antes da aplicação, os teores de ex-Ca oscilaram entre 32,75 e 75,68 $mmol_c dm^{-3}$ e, após a aplicação, entre 31,48 e 106,51 $mmol_c dm^{-3}$. Enquanto o ex-K oscilou entre 2,48 e 13,15 $mmol_c dm^{-3}$, antes da aplicação, e 3,44 e 17,20 $mmol_c dm^{-3}$, depois da aplicação. O aumento do ex-Ca é notavelmente maior frente ao de ex-K dada a maior solubilidade e capacidade do calcário de liberar Ca^{2+} para o ambiente quando comparado com o pó de rocha. Em suma, o comportamento observado dos teores totais e disponíveis de Ca e K indica a mudança da relação entre ambos, principalmente após a aplicação em 2022.

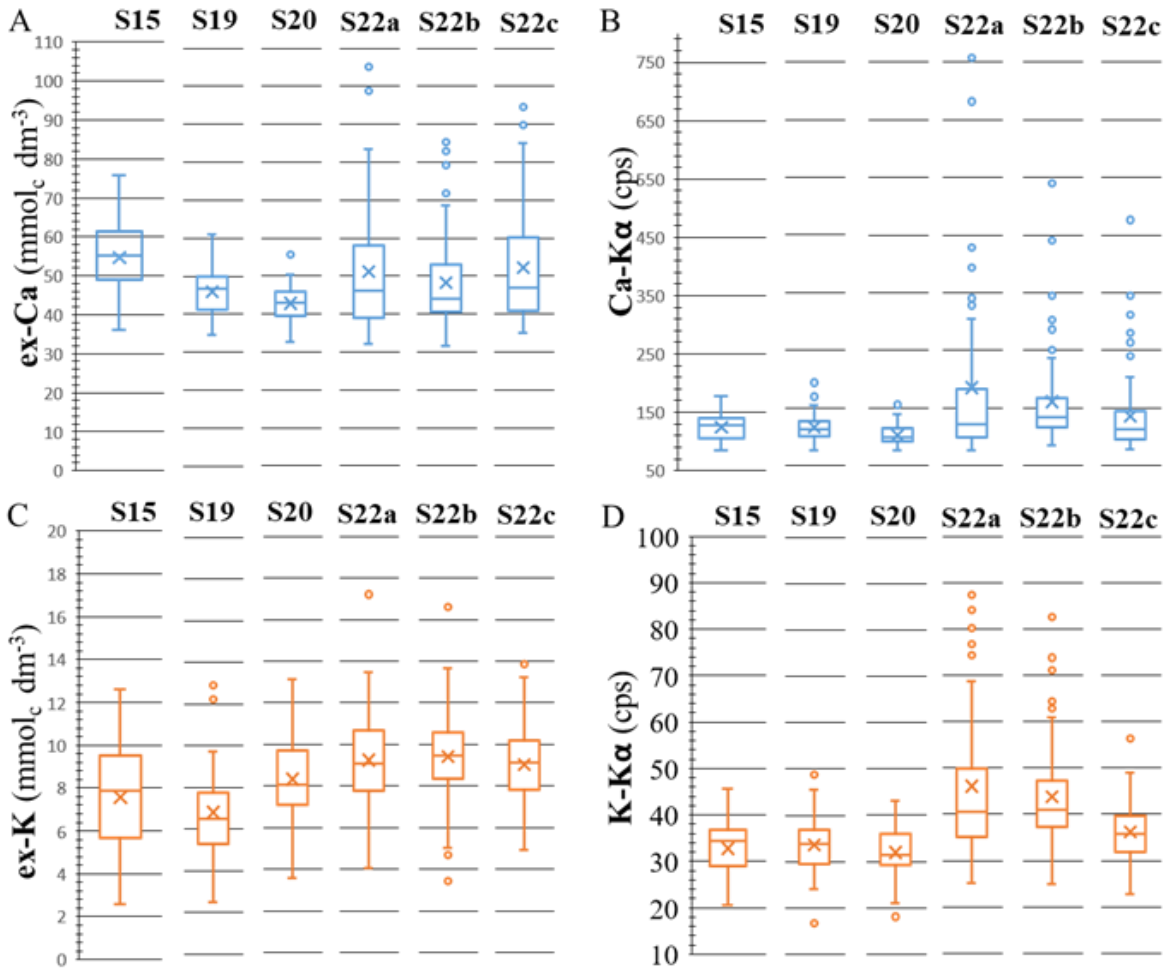


Figura 3. Boxplot mostrando a variação dos teores disponíveis de Ca e K (A e C, respectivamente), bem como a contagem de fótons por segundo (cps) da linha de emissão Ca-Kα e K-Kα (B e D respectivamente) das 6 amostragens conduzidas neste estudo (S15, S19, S20, S22a, S22b e S22c) entre os anos de 2015 e 2022.

Ao analisar a Figura 4 que mostra a regressão linear entre teores totais e disponíveis, é observado uma menor variação no coeficiente angular (α) para Ca e K antes da adubação de 2022 (S15, S19 e S20) em comparação a pós-aplicação (S22a, S22b e S22c). Antes da adubação o α variou entre 0,23?0,25, para Ca, e entre 0,34-0,40, para K, i.e., permanecendo relativamente estável. Por outro

lado, após a aplicação (S22a, S22b e S22c),

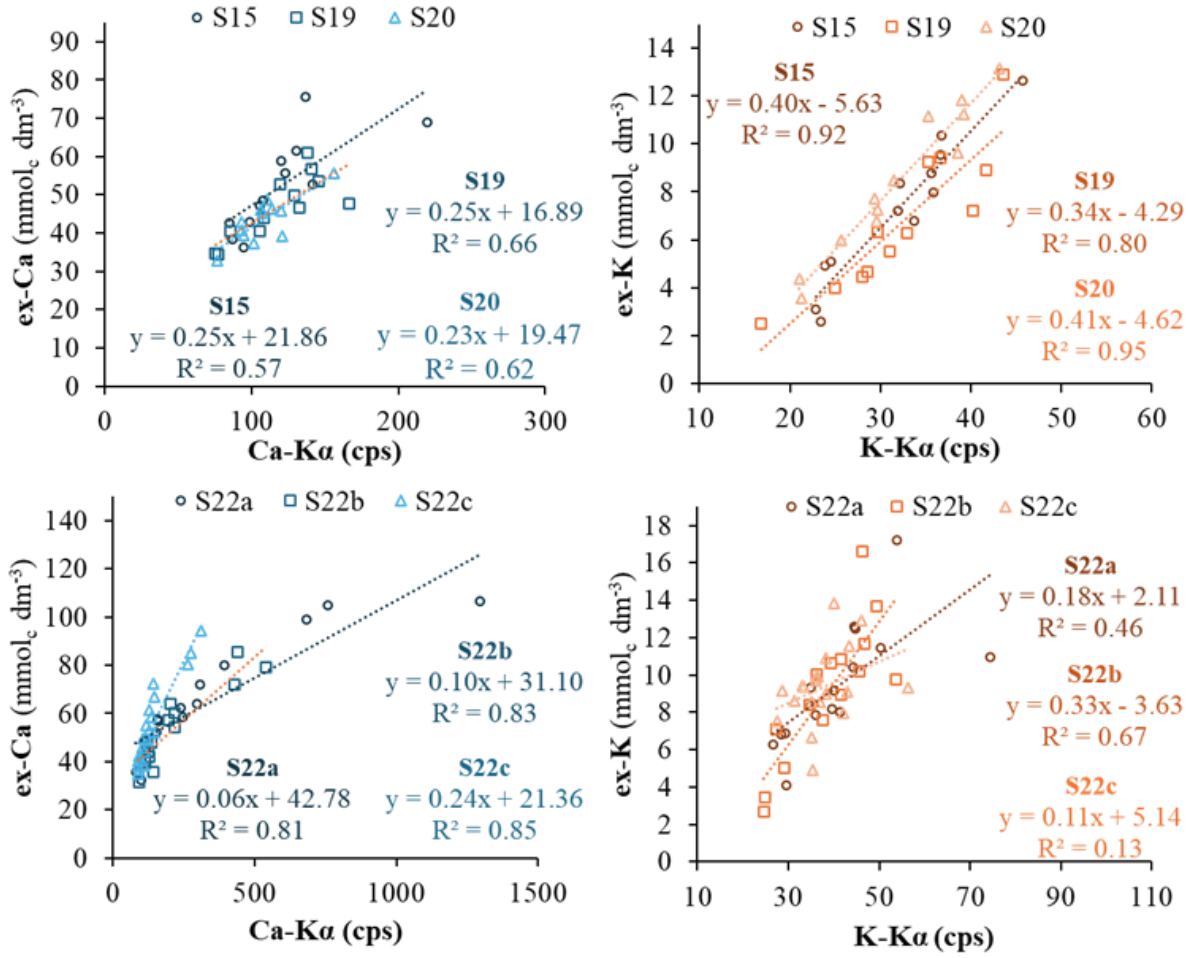


Figura 4. Gráfico de dispersão mostrando a relação entre os teores totais e disponíveis para a planta de Ca (A e C) e K (B e D) entre 2015 a 2022.

o α oscilou entre 0,06?0,24, para Ca, e entre 0,11?0,33, para K. Esse comportamento evidencia a mudança da relação entre teores totais e disponíveis após a aplicação das diferentes doses de calcário e pó de rocha da adubação realizada em 2022.

Os modelos de ex-Ca e ex-K (figura 5) calibrados em 2015 apresentam RMSE estável para as amostragens conduzidas em 2015, 2019 e 2020 (com erro oscilando entre 6,56 e 4,28 mmol$_c$dm^{-3}, para o ex-Ca, e entre 1,25 e 1,64 mmol$_c$dm^{-3}, para o ex-K). Por sua vez, um abrupto aumento do RMSE é observado para as coletas de 2022, posteriores as aplicações de calcário e pó de rocha (com erro oscilando entre 10,78 e 40,64 mmol$_c$dm^{-3}, para o ex-Ca, e entre 1,86 e 6,37 mmol$_c$dm^{-3}, para o ex-K). Além disso, observamos que a dispersão de pontos claramente perde sua linearidade em torno da reta 1:1 nas predições após a aplicação dos insumos (i.e., S22a, S22b e S22c). Esse comportamento mostra que embora os erros dos modelos do XRF tenham mostrado estabilidade temporal para as extrapolações de 2019 e 2020, a alteração do manejo de adubação da área com calcário e pó de rocha afeta esta estabilidade de desempenho.

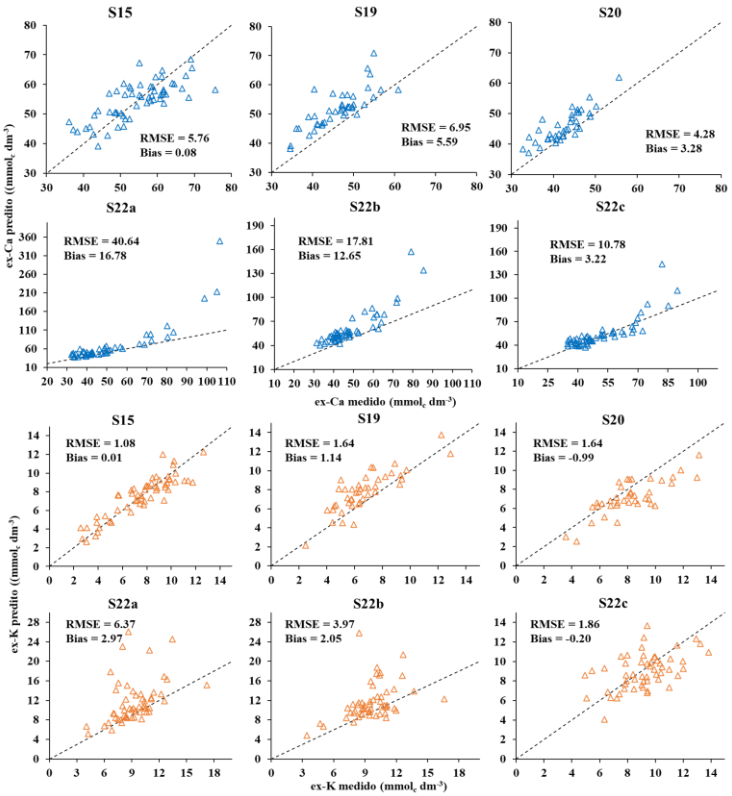


Figura 5. Gráficos de dispersão medidos versus preditos para ex-Ca (em azul) e ex-K (em laranja) calibrando em 2015 e extrapolados para as amostras de S15, S19, S20, S22a, S22b e S22c junto a respectivas figuras de mérito.

CONCLUSÃO

Este trabalho mostrou que modelos XRF locais para predição de ex-Ca e ex-K apresentaram estabilidade temporal no seu desempenho ao serem replicados em anos subsequentes que não tiveram mudança de manejo (i.e., aplicação de doses de calcário e pó de rocha). A mudança do manejo com a aplicação de doses de calcário e pó de rocha potássica alterou o desempenho dos modelos XRF em amostragens conduzidas até 7 meses após a aplicação. Os resultados obtidos sugerem que amostras que receberam aplicações recentes de calcário e pó de rocha devem ser desconsideradas de bibliotecas espectrais de sensores.

REFERÊNCIAS

ANDRADE, R.; FARIA, W.M.; SILVA, S.H.G.; CHAKRABORTY, S.; WEINDORF, D.C.; MESQUITA, L.F.; GUILHERME, L.R.G.; CURI, N. Prediction of soil fertility via portable X-ray fluorescence (pXRF) spectrometry and soil texture in the Brazilian Coastal Plains. **Geoderma**, v. 357, 1 jan. 2020

GIANELLO, C., & AMORIM, M. B. Ammonium Chloride Solution as an Alternative Laboratory Procedure for Exchangeable Cations in Southern Brazilian Soils. **Communications in Soil Science and Plant Analysis**, 46(sup1), 94-103. 2015.

KANIU, M. I.; ANGEYO, K. H.; MWALA, A. K.; MANGALA, M. J. Direct rapid analysis of trace bioavailable soil macronutrients by chemometrics-assisted energy dispersive X-ray fluorescence and scattering spectrometry. **Analytica Chimica** Acta, v. 729, p. 21-25, 1 jun. 2012.

MOLIN, J.P.; TAVARES, T.R. Sensor systems for mapping soil fertility attributes: challenges, advances, and perspectives in brazilian tropical soils. **Engenharia Agrícola**, v.39, p.126-147, 2019.

NAWAR, S.; DELBECQUE, N.; DECLERCQ, Y.; DE SMEDT, P.; FINKE, P.; VERDOODT, A.; VAN MEIRVENNE, M.; MOUAZEN, ABDUL M.. Can spectral analyses improve measurement of key soil fertility parameters with X-ray fluorescence spectrometry? **Geoderma**, v.350, p.29-39, 2019.

RIEBE, D.; ERLER, A.; BRINKMANN, P.; BEITZ, T.; LÖHMANNSRÖBEN, H.; GEBBERS, R.. Comparison of calibration approaches in laser-induced breakdown spectroscopy for proximal soil sensing in precision agriculture. **Sensors** , v. 19, n. 23, 2019..

SILVA, S.H.G.; TEIXEIRA, A.F.D.S.; MENEZES, M.D.D.; GUILHERME, L.R.G.; MOREIRA, F.M.D.S.; CURI, N. et al. Regressão linear múltipla e random forest para predição e mapeamento de atributos do solo utilizando dados de espectrômetro portátil de fluorescência de raios-X (pXRF). **Ciencia e Agrotecnologia**, v. 41, n. 6, p. 648-664, 1 nov. 2017.

TAVARES, T.R.; MOLIN, J.P.; NUNES, L.C.; ALVES, E.E.N.; MELQUIADES, F.L.; CARVALHO, H.W.P.; MOUAZEN, A.M. Effect of X-Ray Tube Configuration on Measurement of Key Soil Fertility Attributes with XRF. **Remote sensing**. v. 12, p. 963, 2020a

TAVARES, T. R. et al. Assessing soil key fertility attributes using a portable X-ray fluorescence: A simple method to overcome matrix effect**. Agronomy**, v. 10, n. 6, 1 jun. 2020b.

TAVARES, T. R. et al. Multi-sensor approach for tropical soil fertility analysis: Comparison of individual and combined performance of vnir, xrf, and libs spectroscopies. **Agronomy**, v. 11, n. 6, p. NA, 21 maio 2021

TEIXEIRA, A. F. DOS S. et al. Portable x-ray fluorescence (pXRF) spectrometry applied to the prediction of chemical attributes in inceptisols under different land use**. Ciencia e Agrotecnologia**, v. 42, n. 5, p. 501-512, 1 set. 2018.

WEINDORF, D.C.; CHAKRABORTY, S. Portable X?ray fluorescence spectrometry analysis of soils. **Soil Science Society of America Journal**, v. 84. n. 5, p.1384-1392, 2020.

DESENVOLVIMENTO DE SISTEMA WEB PARA MONITORAMENTO DA OCORRÊNCIA DE CIGARRINHA-DO-MILHO (*Dalbulus maidis*) NO ESTADO PARANÁ

Anderson de Toledo [1]; Ricardo Theis Geraldi [2]; Daniel Prado de Campos [3]
[1]Pesquisador. Londrina - PR. Instituto de Desenvolvimento Rural do Paraná - IAPAR-EMATER (IDR-Paraná); [2]Professor/Pesquisador. Campo Grande - MS. Faculdade de Computação - Universidade Federal de Mato Grosso do Sul (FACOM-UFMS); [3]Professor/Pesquisador. Apucarana - PR. Universidade Tecnológica Federal do Paraná (UTFPR)

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
O Brasil é um dos principais produtores e exportadores de milho, sendo o Paraná o segundo maior produtor nacional desta cultura. O surgimento recente do Complexo do Enfezamento do Milho tem afetado significativamente sua produtividade agrícola, com casos de registro de até 100% de perdas. O controle de seu principal inseto vetor, a cigarrinha-do-milho (*Dalbulus maidis*), se torna uma das principais medidas de seu controle fitossanitário. Desta forma, a partir de uma parceria entre o IDR-Paraná, a UFMS e a UTFPR-Apucarana, foi desenvolvido um sistema para monitoramento da ocorrência deste inseto vetor. O sistema web (acesso via navegador de internet) possui funcionalidades para a inserção, consulta, alteração e exclusão de pontos de coleta geolocalizados, distribuídos em diversos municípios no Estado do Paraná. A primeira versão do sistema web, denominado "CigarrinhaWeb", passou pelas fases de desenvolvimento, testes e implantação e encontra-se na fase de validação, que será realizada durante a safra de milho 2024/2025 por técnicos do IDR-Paraná. A partir da coleta dos dados e após a validação do sistema, as informações serão disponibilizadas aos produtores rurais, tornando-se, a princípio, uma ferramenta de alerta para a presença do inseto vetor das doenças causadoras do Complexo do Enfezamento do Milho.

PALAVRAS-CHAVE: Complexo de Enfezamento do Milho; Inseto vetor; Sistema Web

ABSTRACT
Brazil is one of the main producers and exporters of corn, with the state of Paraná being the second largest national producer of this crop. The recent emergence of the Corn Stunt Disease Complex has significantly affected its agricultural productivity, with cases of up to 100% losses recorded. Controlling its main insect vector, the corn leafhopper (*Dalbulus maidis*), has become one of the main phytosanitary control measures. Thus, a partnership between IDR-Paraná, UFMS and UTFPR-Apucarana has led to the development of a system to monitor the occurrence of this insect vector. The web application (accessed via an internet browser) has functions to create, read, update and delete (CRUD) of geolocated collection points in various municipalities in the state of Paraná. The first version of the system, called "CigarrinhaWeb", has gone through the development, testing and implementation phases and is now in validation, which will be carried out by IDR-Paraná team during the 2024/2025 season. Once the data has been collected and the system validated, the data will be available to rural producers, becoming a presence alert tool of Corn Stunt Disease Complex's insect vector.

KEYWORDS: Corn Stunt Disease Complex; Insect vector; Web Application

INTRODUÇÃO

A produção de milho (*Zea mays* L.) representa a segunda *commodity* agrícola mais importante para o Brasil, com produção estimada de 115,65 milhões de toneladas em 20,96 milhões de hectares na

safra de 2023/24, sendo o Paraná o segundo maior produtor nacional, com 13,4% da produção (CONAB, 2024). Contudo, o aumento da área plantada nos últimos anos e a ampla janela de semeadura que ocorre com milho safra, segunda safra ("safrinha") e terceira safra, criam a denominada "ponte verde", que tem sido associado ao favorecimento da perpetuação de pragas e patógenos (OLIVEIRA; FRIZZAS, 2022). Entre os problemas fitossanitários na cultura do milho, destaca-se atualmente o Complexo de Enfezamento, que tem causado grandes danos à cultura, acarretando perdas de até 100% da produção (COTA et al., 2021). A cigarrinha *Dalbulus maidis* (DeLong & Wolcott) (Hemiptera, Cicadellidae) é considerada uma das principais pragas da cultura do milho na América Latina (OLIVEIRA; FRIZZAS, 2022), sendo responsável pela transmissão dos três patógenos causadores do enfezamento (WAQUIL et al., 1999). O controle do Complexo Enfezamento do Milho pode ser realizado com adoção do manejo integrado, incluindo ações desde a semeadura até a colheita e transporte dos grãos, pois ações pontuais não resolvem o problema. Dentre outras, destaca-se, durante o cultivo do milho, o monitoramento da presença de cigarrinhas entre as fases VE e V8 (ALVES et al., 2020). A identificação dos patógenos que compõem o complexo enfezamento do milho no Estado é importante pois, auxilia no direcionamento dos estudos de seleção e criação de cultivares e híbridos menos susceptíveis à doença. Assim, torna-se importante determinar o histórico de ocorrência dos patógenos e sua distribuição nas diferentes regiões produtoras de milho, a fim de determinar quais populações do inseto vetor estão infectivas e com maior potencial de dano. Desta forma, este trabalho apresenta o desenvolvimento de um sistema de monitoramento da cigarrinha-do-milho no Estado do Paraná.

OBJETIVOS

Desenvolver um sistema web para registro, visualização e monitoramento da cigarrinha-do-milho no Estado do Paraná.

MATERIAL E MÉTODOS

A partir de uma parceria entre o Instituto de Desenvolvimento Rural do Paraná - IAPAR-EMATER (IDR-Paraná), a Faculdade de Computação (FACOM) da Universidade Federal de Mato Grosso do Sul (UFMS) e a Universidade Tecnológica Federal do Paraná - Campus Apucarana (UTFPR-Apucarana), com apoio da Fundação Araucária e do Serviço Nacional de Aprendizagem Rural do Paraná (SENAR-PR), foi desenvolvido um sistema web de monitoramento em plataforma web (acesso via navegador pela internet) para registro, visualização e atualização dos dados obtidos pela coleta, identificação taxonômica e contagem dos insetos de cigarrinha-do-milho nas armadilhas utilizadas pelo IDR-Paraná para este fim. Este projeto é integrante da "Rede de Agropesquisa Complexo Enfezamento do Milho no Paraná" (https://www.iaraucaria.pr.gov.br/napi-enfezamento/).

A primeira etapa do projeto contemplou a definição de critérios e requisitos funcionais e não-funcionais do sistema web, realizada em conjunto por meio de reuniões entre as equipes das instituições. Para o desenvolvimento foi utilizada linguagem de programação *JavaScript* utilizando o ambiente de execução *Node.js* (https://nodejs.org/), e para o banco de dados o *PostgreSQL* (https://www.postgresql.org/). O código-fonte de desenvolvimento do sistema foi disponibilizado entre a equipe por meio de acesso a repositórios compartilhados, utilizando softwares de versionamento baseado em *Git*, como o *Github* (https://github.com/). O sistema web desenvolvido tem as funções do tipo CRUD (*Create, Read, Update and Delete*) que permite criar, consultar, alterar e excluir os dados inseridos no sistema de monitoramento. A implantação do sistema foi realizada por meio de virtualização em contêiner via *Docker* (https://docker.com/), hospedado em servidor do IDR-Paraná e disponibilizado publicamente na internet.

RESULTADOS E DISCUSSÃO

Desenvolvimento

Por se tratar de um sistema do tipo CRUD, ele consiste, especificamente, no cadastramento de usuários (Técnicos), dos pontos de coleta geolocalizados (Armadilhas) e das contagens dos insetos presentes nas armadilhas amarelas dispostas no campo (Coletas). As funcionalidades desenvolvidas para o sistema, denominado "CigarrinhaWeb", representadas no Diagrama de Caso de Uso da Figura 1, são: Visualizar Coletas, Fazer Login, Manter Coletas, Manter Armadilhas e Manter Usuários. Todos os perfis de usuário tem acesso à funcionalidade Visualizar Coletas; as funcionalidades Fazer Login e Manter Coletas estão disponíveis somente para os perfis Técnico e Administrador e, por fim, somente o Administrador tem acesso às funcionalidades Manter Armadilhas e Manter Usuários.

Conforme a Figura 1, que representa o Diagrama de Caso de Uso do sistema, foram definidos três perfis de usuários para o sistema: Público, Técnico e Administrador. O usuário do tipo Público pode acessar o sistema e visualizar as Coletas mais recentes registradas no sistema, conforme exibido na Figura 2. Nenhum nível de acesso é exigido para esse perfil de usuário. Para o perfil de usuário do tipo Técnico, além de poder visualizar as Coletas, é possível realizar o Login no sistema, utilizando *e-mail* e senha fornecidos pelo Administrador do sistema, e que permite ao Técnico acesso à funcionalidade de Manter Coletas, ou seja, cadastrar nova Coleta, editá-la ou excluí-la do sistema. O perfil de Técnico possui um filtro regionalizado (Região), definido com base nas sete Mesorregiões do Estado do Paraná (Centro, Centro-sul, Metropolitana e Litoral, Noroeste, Norte, Oeste e Sudoeste), restringindo o acesso do Técnico e, consequentemente, limitando a funcionalidade Manter Coletas às Armadilhas cadastradas para sua Mesorregião, de acordo com o município de instalação de cada Armadilha. O perfil de usuário Administrador possui acesso à todas as funcionalidades, sendo responsável por criar, alterar ou excluir os demais usuários Técnicos ou Administradores, as Coletas e as Armadilhas registradas no sistema.

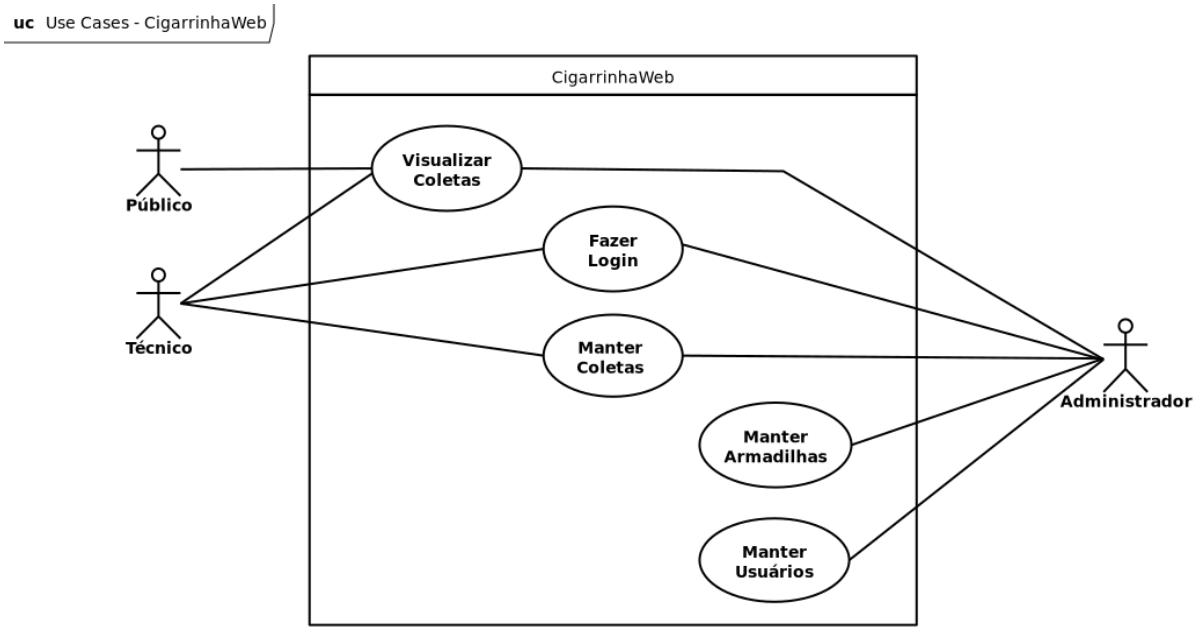


FIGURA 1. Diagrama de Caso de Uso do sistema CigarrinhaWeb.

Testes e implantação

Ao final do desenvolvimento da primeira versão do sistema, antes da implantação e disponibilização do sistema para validação, procedeu-se à fase de testes, que contemplaram principalmente testes de usabilidade e desempenho. Alguns erros foram identificados nesta fase, sendo reportados à equipe de desenvolvimento, sendo corrigidos antes da implantação. Para a etapa de implantação, o sistema foi disponibilizado na forma de contêiner *Docker*, sendo realizada a instalação em um computador-servidor do IDR-Paraná, com acesso disponível pela internet.

Validação

A rápida constatação do inseto na área é um dos principais pontos chave para o manejo de doenças transmitidas por insetos vetores, principalmente em regiões com o histórico da doença. Portanto, é imprescindível o constante monitoramento dos insetos na área de produção e a nível regional, permitindo determinar a intensidade de ocorrência e distribuição espacial das cigarrinhas nas regiões de cultivo. Para a etapa de validação do sistema estão sendo utilizadas armadilhas amarelas adesivas, adaptadas para o monitoramento de *D. maidis*, instaladas em 28 localidades abrangendo as principais regiões produtoras de milho do Estado na safra e safrinha de milho 2024/2025. Conforme protocolo definido pela equipe técnica, semanalmente, técnicos do IDR-Paraná devidamente treinados na identificação, irão vistoriar e quantificar os adultos de *D. maidis* capturados pelas armadilhas, cujos dados serão inseridos no sistema. O sistema disponibilizará as informações em uma página pública para visualização das coletas, exibindo o valor da última Coleta registrada em cada Armadilha (Figura 2).

Uso do sistema

A primeira etapa para a utilização e cadastro de dados no sistema, é realizada pelo usuário Administrador, cujo *Dashboard* para seu perfil de usuário pode ser visualizado na Figura 3. O Administrador é responsável pelo cadastramento inicial das Armadilhas (Figura 4), em que deve fornecer as seguintes variáveis para cada Armadilha: Nome, Descrição, Região, Unidade Regional e Município. As variáveis de Latitude e Longitude são obtidas automaticamente com base no Município selecionado, podendo também ser editada manualmente pelo usuário. O Administrador também é responsável pela criação dos usuários com o perfil Técnico, definido ao menos um Técnico para cada Região, como citado anteriormente.

As Coletas devem ser registradas no sistema pelo Técnico, informando as seguintes variáveis: Data, Contagem de *Dalbulus Maidis*, Contagem de *Leptodelphax maculigera*[1], Armadilha (com base na lista de Armadilhas cadastradas pelo Administrador, Figura 5) e Fase de Desenvolvimento do milho (Pré-emergência, VE-Emergência, V1, V3, V7, V10), como apresentado na Figura 6. Cada Técnico somente pode registrar Coletas em Armadilhas contidas em sua Região.

[1] Este inseto também foi identificado como potencial transmissor do Complexo do Enfezamento do Milho (FERREIRA et al., 2023). Portanto, o monitoramento de sua ocorrência também foi incluído no sistema.

Após o cadastramento das Armadilhas e Coletas, o sistema exibirá automaticamente estas informações geoespacializadas no Estado do Paraná, sendo que cada ícone de marcador representa uma Armadilha registrada no sistema e as informações do nome da Armadilha, data da última coleta e quantidade de cigarrinhas contabilizadas em cada Armadilha são exibidas na forma de uma mensagem *pop-up* (Figura 7).

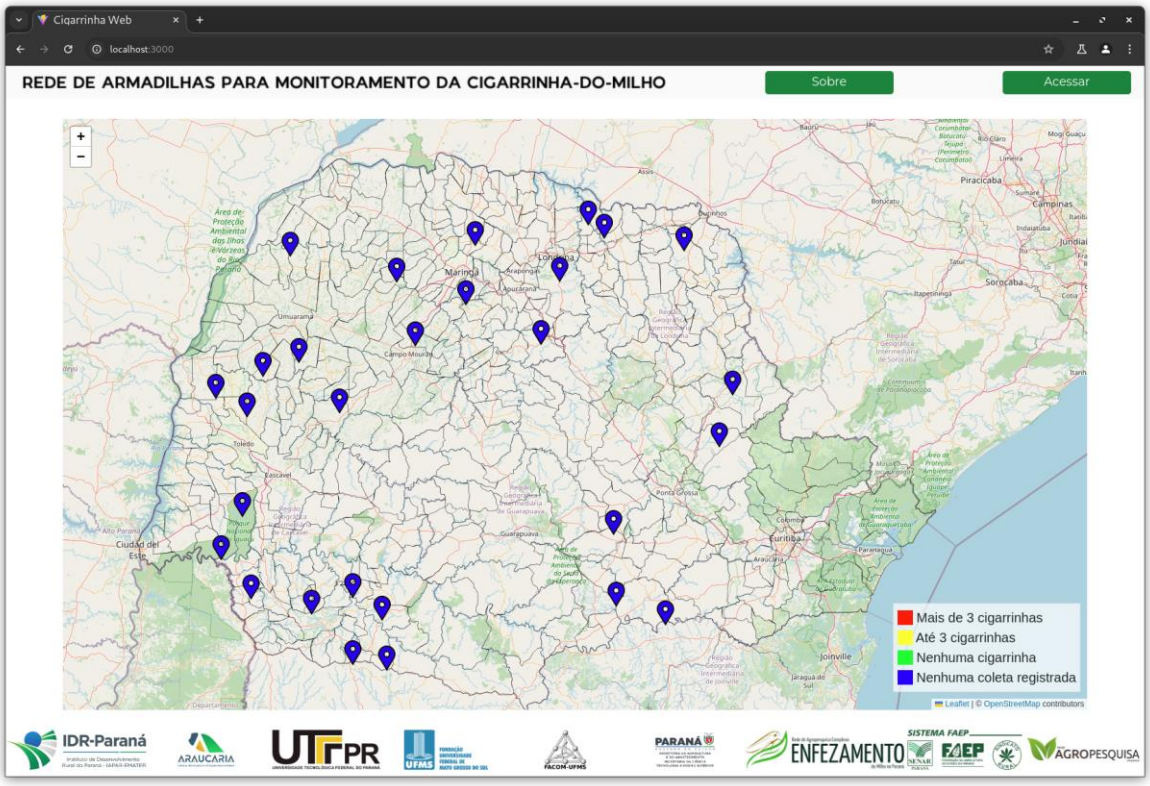


FIGURA 2. Página pública do sistema CigarrinhaWeb com exibição da localização das Armadilhas em diversos municípios do Paraná.

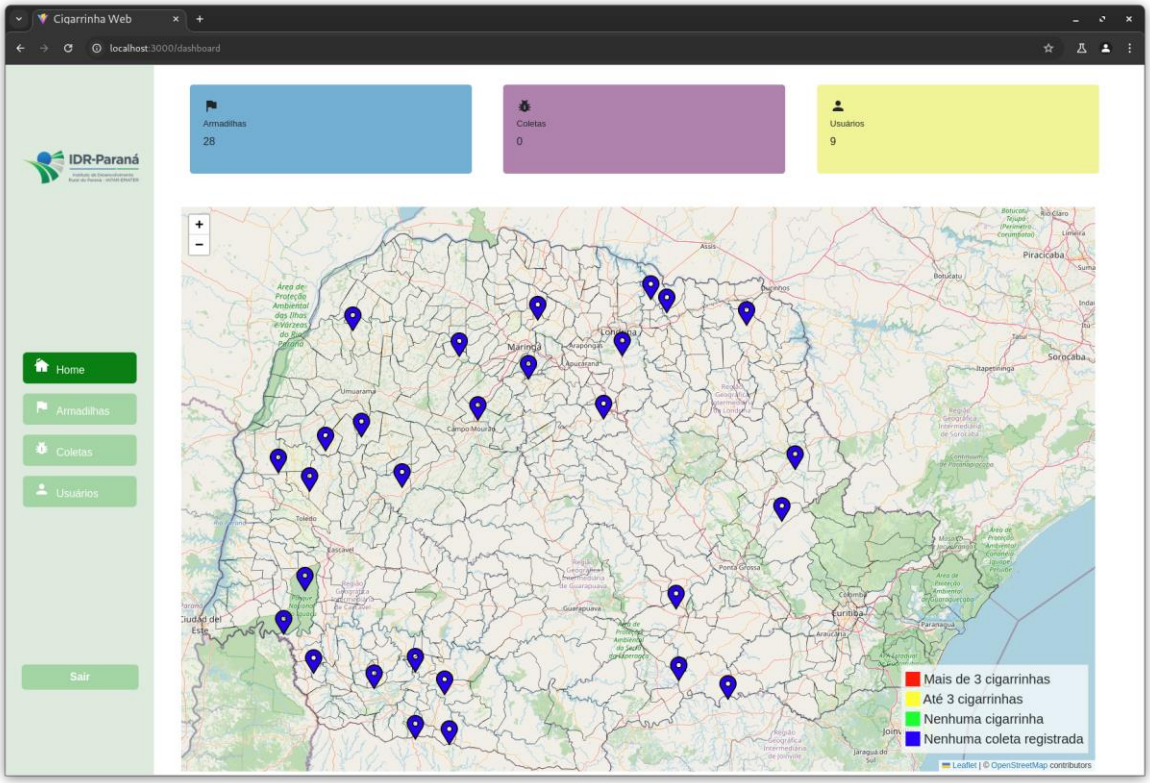


FIGURA 3. Dashboard do administrador do sistema CigarrinhaWeb.

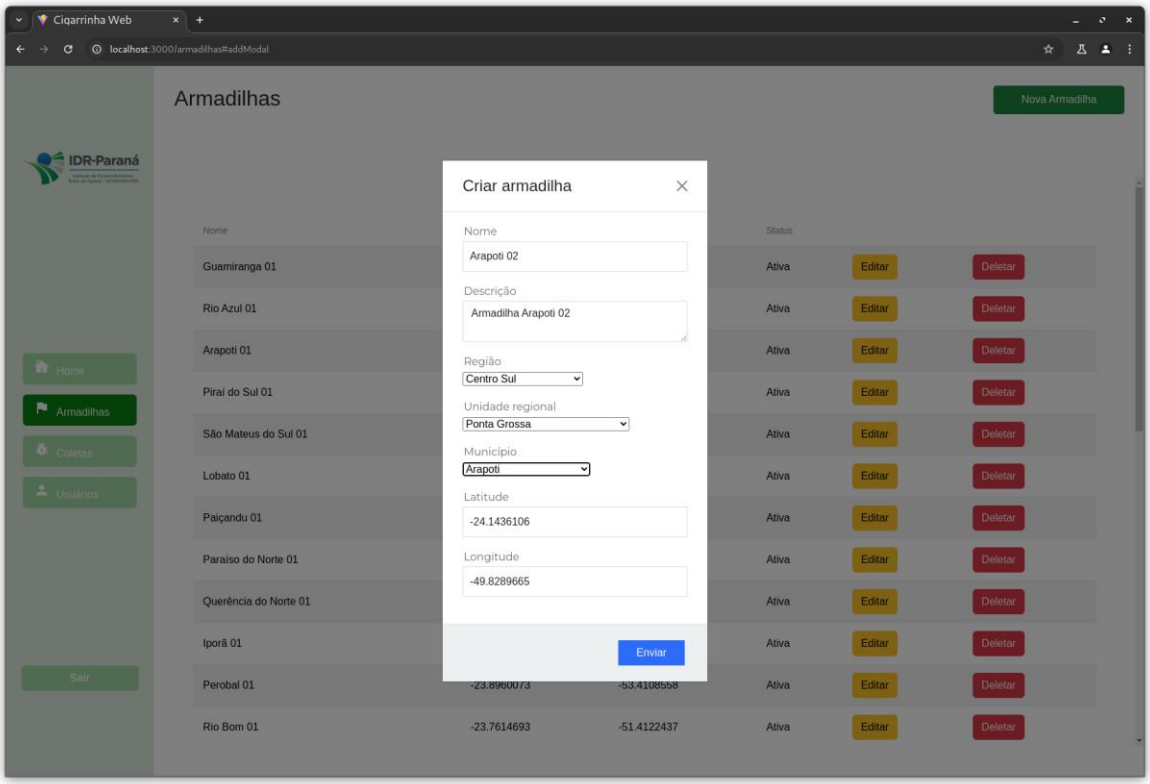


FIGURA 4. Modal de cadastramento de Armadilha (ponto de coleta) do sistema CigarrinhaWeb.

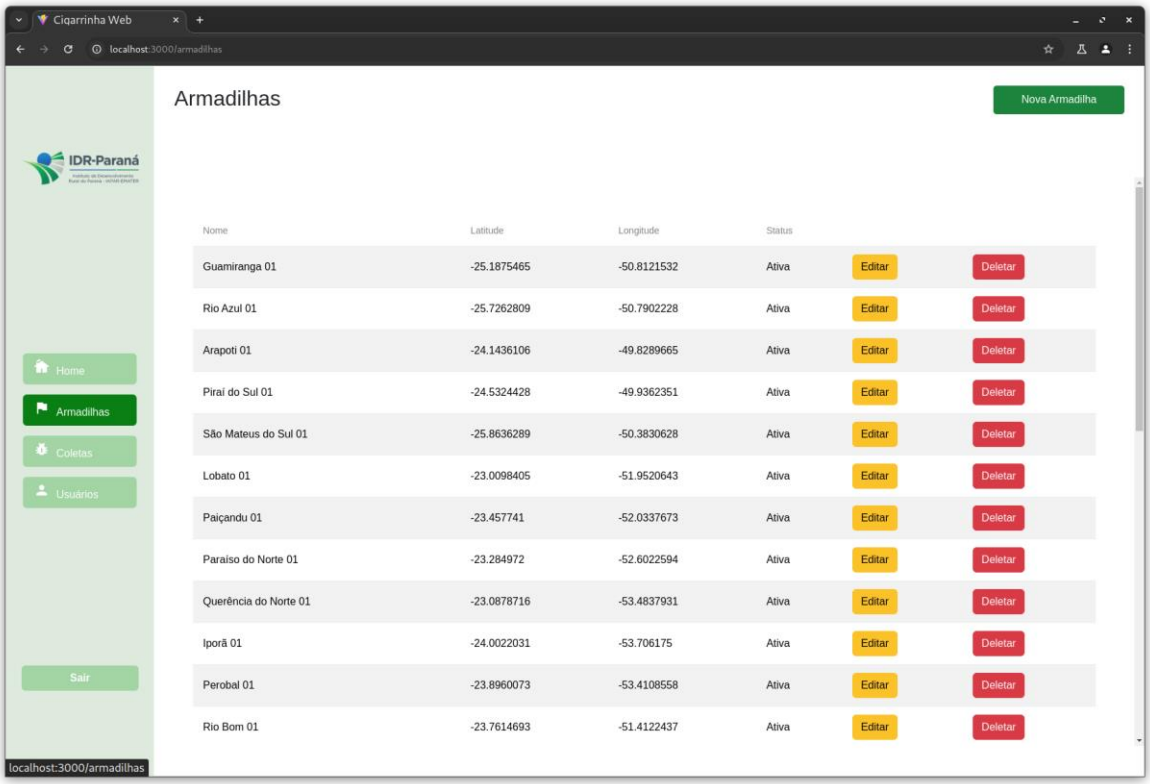


FIGURA 5. Tela com lista de Armadilhas cadastradas (pontos de coleta) no sistema CigarrinhaWeb.

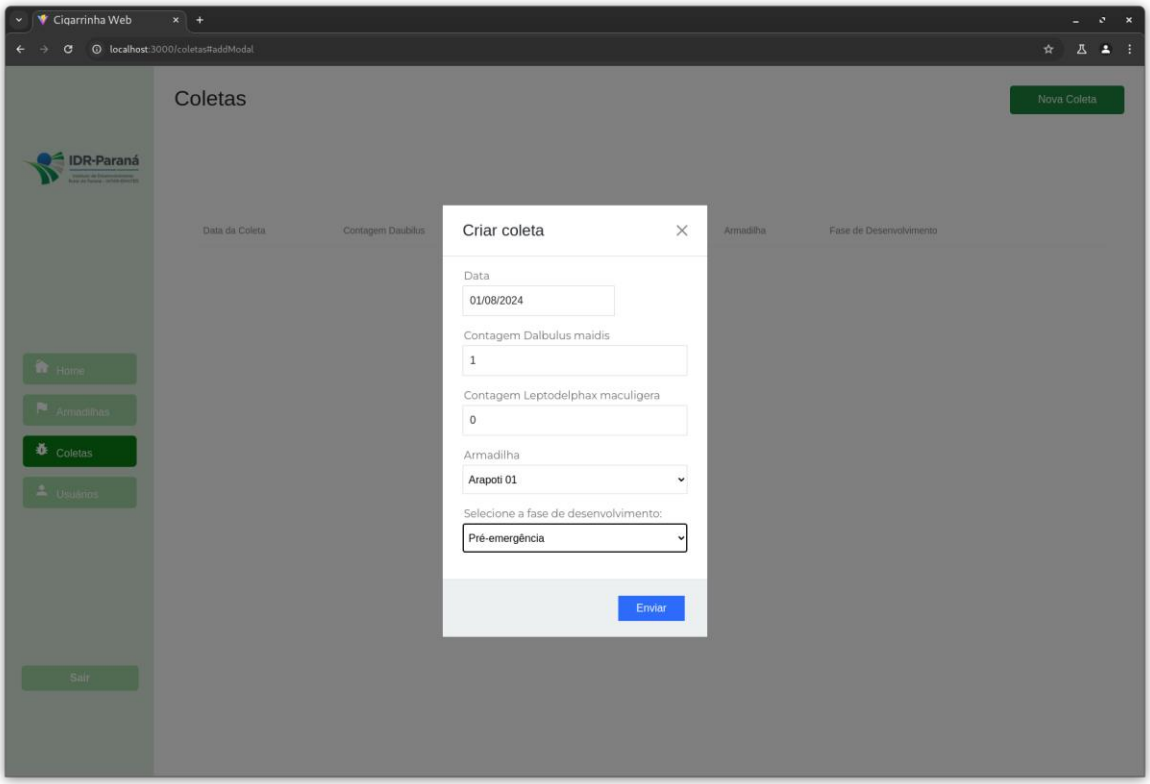


FIGURA 6. Modal de cadastramento de Coleta do sistema CigarrinhaWeb.

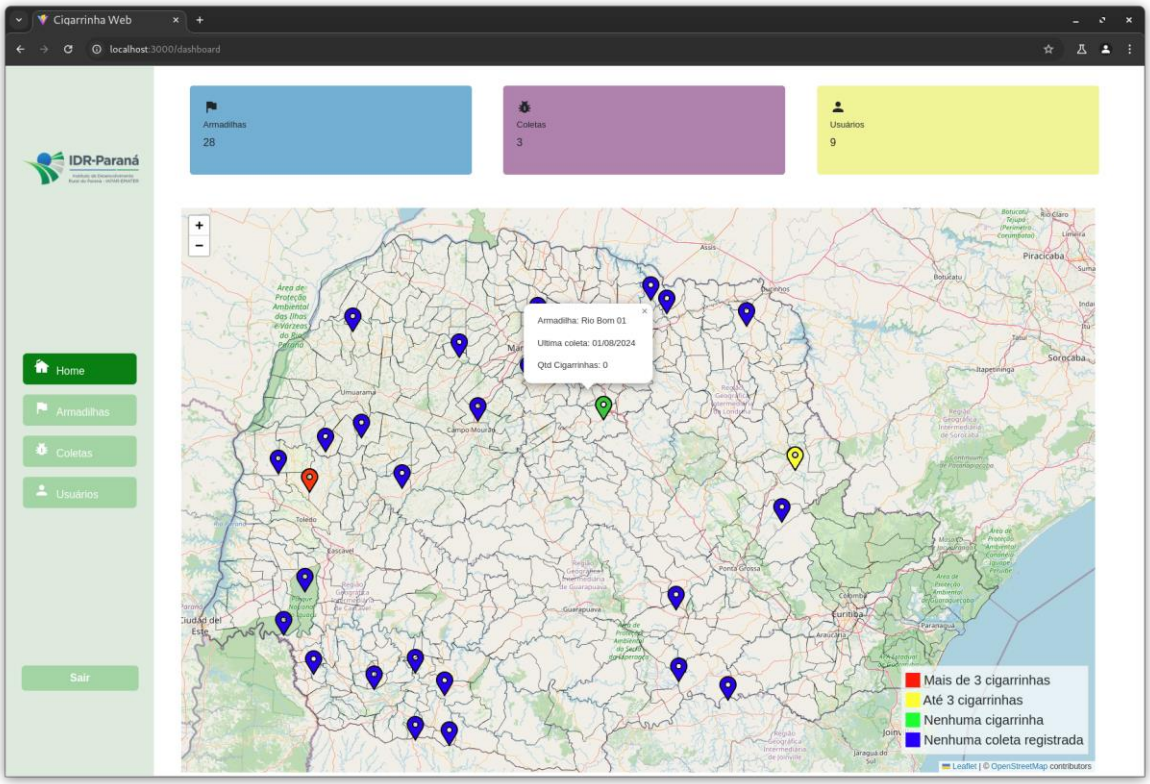


FIGURA 7. Pop-up para visualização da informação de uma Coleta no mapa do sistema CigarrinhaWeb.

Por fim, as cores de cada ícone de Armadilha no mapa representam a escala de infestação de cigarrinhas, com base na contagem registrada no sistema, sendo: verde para contagem igual a zero; amarela para até 3 cigarrinhas; vermelha para mais de 3 cigarrinhas; azul para nenhuma Coleta registrada naquela Armadilha (Figura 7).

CONCLUSÃO

O sistema atendeu ao objetivo proposto de desenvolver um sistema para registro, visualização e monitoramento da cigarrinha-do-milho no Estado do Paraná. Foram criadas funcionalidades de cadastro de usuários, armadilhas e coletas, sem limitações de quantidades, o que permitirá a geração de um banco de dados histórico sobre a ocorrência deste inseto no Estado, gerando bases tecnológicas para futuras pesquisas.

A validação do sistema está sendo realizada pelos técnicos do IDR-Paraná, por meio da inserção dos dados obtidos na safra 2024/2025. Após a validação do sistema, o sistema será disponibilizado publicamente a técnicos e agricultores para acesso e visualização das informações geradas, principalmente referentes à distribuição e ocorrência populacional da cigarrinha-do-milho, como forma de alertá-los para a presença do inseto vetor das doenças causadoras do Complexo do Enfezamento do Milho.

Além disso, estão em desenvolvimento funcionalidades de visualização em forma de mapas de densidade populacional com base na ocorrência temporal e distribuição espacial da cigarrinha-do-milho nas regiões monitoradas com uso das armadilhas, filtros por período/data e emissão de relatórios das coletas registradas no sistema.

AGRADECIMENTOS

À Fundação Araucária e ao SENAR-PR pelo apoio financeiro ao projeto.

REFERÊNCIAS

ALVES, A. P.; PARODY, B.; BARBOSA, C. M.; OLIVEIRA, C. M. de; SACHS, C.; SABATO, E. de O.; GAVA, F.; DANIEL, H.; OLIVEIRA, I. R. de; FORESTI, J.; COTA, L. V.; CAMPANTE, P.; GAROLLO, P. R.; PALATNIK, P.; ARAUJO, R. M. **Guia de boas práticas para o manejo dos enfezamentos e da cigarrinha-do-milho**. São Paulo: Croplife Brasil; Brasília, DF: Embrapa, 2020. 33 p. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/220559/1/Charles-Guia-Boas-Praticas-Cigarinha-do-Milho.pdf>. Acesso em: 06 ago. 2024, 17:03.

CONAB. Companhia Nacional de Abastecimento. **Portal de Informações Agropecuárias**: Acompanhamento da safra brasileira de grãos (11ºLevantamento). Brasília: Conab, 2024. Disponível em: <https:// portaldeinformacoes.conab.gov.br/safra-estimativa-de-evolucao-graos.html>. Acesso em: 19 ago. 2024, 15:51.

COTA, L. V.; OLIVEIRA, I. R. de; SILVA, D. D. da; MENDES, S. M.; COSTA, R. V. da; SOUZA, I. R. P. de; SILVA, A. F. da. **Manejo da cigarrinha e enfezamentos na cultura do milho**. Sete Lagoas: Embrapa Milho e Sorgo, 2021. 16 p. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/225303/1/Cartilha-Manejo-cigarrinha-enfezamentos-milho.pdf>. Acesso em: 09 ago. 2024, 15:47.

FERREIRA, K.R.; BARTLETT, C.R.; ASCHE, M.; SILVA, LR.S.; MAGALHÃES, V.S.; GONDINHO, KC.A. First record of the African species *Leptodelphax maculigera* (Stål, 1859) (Hemiptera: Delphacidae) in Brazil. **Research Square**, PREPRINT, 2023. Disponível em: <https://doi.org/10.21203/rs.3.rs-2818951/v1>. Acesso em 20 ago. 2024, 16:17.

OLIVEIRA, C.O.; FRIZZAS, M.R. Eigth decades of *Dalbulus maidis* (DeLong & Wolcott) (Hemiptera, Cicadellidae) in Brazil: What we know and what we need to know. **Neotropical Entomology**, v.51, n.1, p.1-17, 2021.

WAQUIL, J.M.; VIANA, P.A.; CRUZ, I.; SANTOS, J.P. Aspectos da biologia da cigarrinha-do-milho, *Daubulus maidis* (DeLong &Wolcott) (Hemiptera: Cicadellidae). **Anais da Sociedade Entomológica do Brasil**, v.28, n.3, p.413-420, 1999.

USO DE CÂMERAS TÉRMICAS NA DETECÇÃO PRECOCE DE *Meloidogyne exigua* EM CAFEZAIS: UM ESTUDO NA REGIÃO SUL DE MINAS GERAIS

Luana Mendes dos Santos [1]; Felipe Augusto Fernandes [2]; Daniele de Brum [3]; Marco Antonio Zanella [4]; Patrícia Ferreira Ponciano Ferraz [5]; Gabriel Araújo e Silva Ferraz [5]

[1]Docente. BR 287, km 360, Estrada do Chapadão, sn- CEP 97.760-000 Jaguari- Rio Grande do Sul/ RS. Instituto Federal da Farroupilha- Campus Jaguari; [2]Pesquisador . Cidade Universitária Zeferino Vaz - Barão Geraldo, Campinas - SP, 13083-970. Universidade Estadual de Campinas- UNICAMP; [3]Doutoranda em Fitopatologia. Trevo Rotatório Professor Edmir Sá Santos Universidade Federal de, Lavras - MG, 37203-202. Universidade Federal de Lavras- UFLA; [4]Docente. R. Dom Manoel de Medeiros, s/n, Dois Irmãos, Recife (PE). Universidade Federal Rural de Pernambuco- UFRPE; [5]Docente. Trevo Rotatório Professor Edmir Sá Santos Universidade Federal de, Lavras - MG, 37203-202. Universidade Federal de Lavras- UFLA

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Este estudo investigou o potencial das câmeras térmicas na detecção precoce do nematoide das galhas, *Meloidogyne exigua*, em cafezais, considerando a importância econômica do café e os desafios enfrentados pelos produtores devido à doença causada pelo patógeno. Assim, objetivou-se avaliar temperatura média das plantas de café, coletadas nos lados direito e esquerdo das plantas, durante os meses de maio e outubro de 2020, e sua relação com a presença do nematoide em uma lavoura cafeeira. Foi realizado um levantamento das condições climáticas em uma região produtora de café no Sul de Minas Gerais, durante os meses de maio e outubro de 2020, com ênfase na temperatura média das plantas. Utilizou-se uma câmera térmica para coletar dados de temperatura média nos lados direito e esquerdo das plantas. Os resultados indicaram correlação significativa entre a temperatura das plantas e a infestação do nematoide, com variações observadas entre os lados da planta e os meses de coleta. Esses achados destacam o potencial das câmeras térmicas como ferramenta de diagnóstico precoce de problemas fitossanitários em cafezais, oferecendo uma abordagem não invasiva e eficiente para monitorar a saúde das plantas. Esta pesquisa contribui para o avanço da agricultura de precisão no Brasil, fornecendo insights valiosos para o manejo integrado de doenças em culturas de importância agrícola como o cafeeiro.

PALAVRAS-CHAVE: Termografia; *Meloidogyne*; *coffea arabica*

ABSTRACT

This study investigated the potential of thermal cameras in early detection of nematode infestations in coffee plantations, considering the economic importance of coffee and the challenges faced by producers due to plant diseases. Thus, the objective was to evaluate the average temperature of coffee plants, collected on the right and left sides, during the months of May and October in 2020, and its relationship with the presence of nematodes in a coffee crop. A survey of climatic conditions was carried out in a coffee producing region in the south of Minas Gerais, during the months of May and October, with an emphasis on the average temperature of the plants. A thermal camera was used to collect average temperature data on the right and left sides of the plants. The results indicated a significant correlation between plant temperature and nematode infestation, with variations observed between the sides of the plant and the collection months. These findings highlight the potential of thermal cameras as an early diagnosis tool for phytosanitary problems in coffee plantations, offering a non-invasive and efficient approach to monitoring plant health. This research contributes to the advancement of precision agriculture in Brazil, providing valuable insights for integrated disease management in important agricultural crops such as coffee.

KEYWORDS: ;

INTRODUÇÃO

O café é uma cultura de destaque na economia brasileira, liderando a produção mundial de café arábica, com uma significativa contribuição de 46,4% (USDA, 2024). No estado de Minas Gerais, em especial na região Sul, o café desempenha um papel fundamental, tanto no cenário socioeconômico quanto na subsistência de diversas famílias agrícolas. No entanto, os produtores enfrentam desafios significativos, destacando-se as doenças causadas por nematoides do gênero *Meloidogyne*, popularmente conhecidos por nematoides das galhas, como uma das principais ameaças às lavouras cafeeiras (TERRA et al., 2018). A identificação precoce desses patógenos é crucial para implementar medidas eficazes de manejo, porém, é um desafio devido aos sintomas serem detectáveis apenas em estágios já avançados da doença (PAN et al., 2014). Diante dessa limitação, o avanço da agricultura digital e o desenvolvimento de ferramentas tecnológicas, como as câmeras térmicas, oferecem uma oportunidade promissora para a detecção precoce de problemas fitossanitários, como os causados por patógenos, sem danos às plantas (VIANA et al., 2018; BESSA, 2021). No entanto, apesar do potencial das câmeras térmicas na agricultura, o Brasil ainda carece de pesquisa e aplicação prática nesse campo (VIANA et al., 2018).

OBJETIVOS

Considerando esses aspectos, este estudo teve como objetivo avaliar temperatura média das plantas de café, coletadas nos lados direito e esquerdo das plantas, durante os meses de maio e outubro de 2020, e sua relação com a presença do nematoide das galhas em uma lavoura cafeeira no Sul de Minas Gerais.

MATERIAL E MÉTODOS

A pesquisa ocorreu em um campo experimental na área de cafeicultura do Departamento de Agricultura da Universidade Federal de Lavras, situada em Lavras, Minas Gerais. As imagens foram capturadas em duas datas distintas: 01 de maio de 2020, com uma temperatura no início da coleta de 20 °C, e 28 de outubro de 2020, com uma temperatura no início da coleta de 26 °C. A coleta ocorreu entre 9h30 e 11h30, abrangendo as faces leste e oeste de 20 plantas da cultivar Topázio, com espaçamento de 1,80 metros entre as linhas e 0,70 metros entre as plantas. Utilizou-se a câmera termográfica da marca FLIR modelo E75, com faixa espectral 7,5 a 14,0 µm. As imagens foram tomadas a uma distância de 1,5 metros de cada face das plantas e foram salvas em um cartão de memória SD para posterior análise utilizando o software FLIR Tools. Para determinar a quantidade de galhas de nematoides, foram obtidos cerca de 300 gramas de raízes de plantas de café na zona de projeção da copa, a uma profundidade de 0-20 cm. Essas amostras foram levadas ao laboratório de nematologia da Universidade Federal de Lavras, onde foram lavadas e o número de galhas foi quantificado. Os dados do número de galhas foram associados aos dados de temperatura de ambas as faces das plantas usando correlação de Pearson (R). Além disso, realizou-se um ajuste do modelo de regressão logística binária para classificar as plantas em duas categorias: "Muitas" e "Poucas" galhas de nematoides. Plantas com 100 ou mais galhas foram classificadas como "Muitas", enquanto as com menos de 100 foram classificadas como "Poucas". Todas as análises estatísticas foram realizadas utilizando o software estatístico R (R Core Team, Viena, Áustria).

RESULTADOS E DISCUSSÃO

A correlação entre o número de galhas de nematoides e as temperaturas (direita e esquerda) é ilustrada na Figura 1. A significância das correlações foi testada e mostrou-se significativa a um nível de 5% de significância. Observou-se uma correlação mais forte entre o número de galhas e a temperatura das plantas à esquerda. A temperatura mais elevada no lado esquerdo, que é a face oeste de exposição

solar, é devido à maior incidência direta da luz solar nessa área ao longo do dia. Como resultado, o lado esquerdo geralmente tende a ser mais quente do que o lado direito, especialmente durante certas horas do dia. Além do que, os nematoides geralmente se manifestam durante a estação chuvosa, quando há maior umidade e temperatura, o que pode ser favorecido pela exposição solar mais intensa no lado esquerdo da planta. Esses fatores combinados podem explicar a correlação mais forte entre o número de galhas de nematoides e a temperatura no lado esquerdo. Ademais, na estação chuvosa, com o aumento das temperaturas e maior umidade no solo, as condições se tornam positivas para o desenvolvimento do nematoide. Esses resultados estão alinhados com os achados de Marcuzzo et al. (2000), que observaram um aumento significativo na população de nematoides durante a estação chuvosa, a partir do mês de outubro, enquanto uma população estável (ovos na fase de sobrevivência) foi observada durante a estação seca (maio, junho e julho).

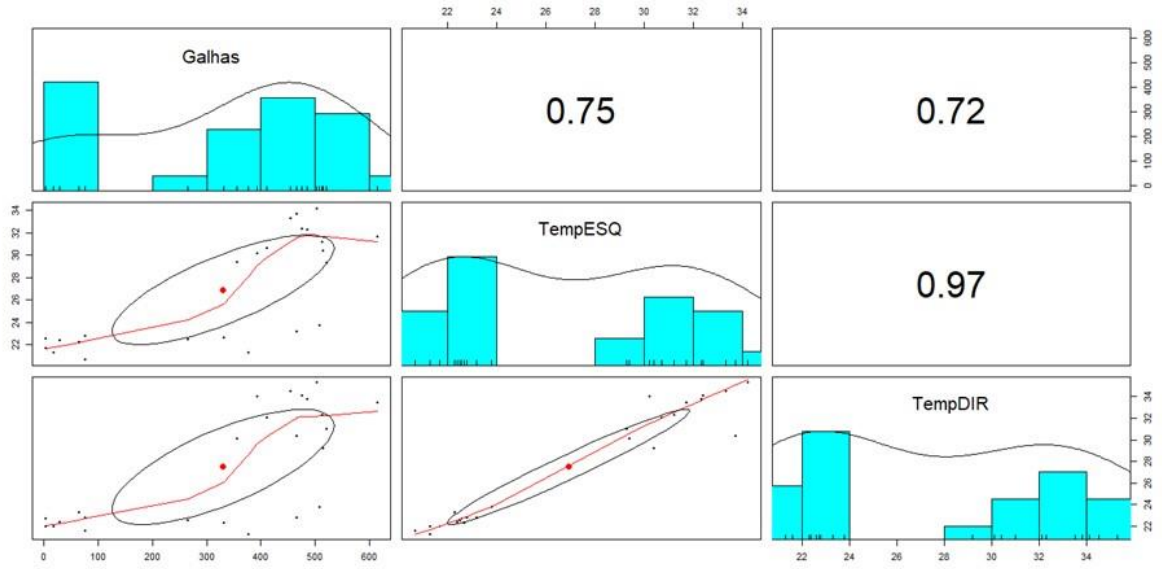


FIGURA 1. Correlação entre o número de galhas de Meloidogyne exigua e as temperaturas (lado direito e lado esquerdo) das plantas de café.

CONCLUSÃO

Com base nos resultados apresentados, conclui-se que a exposição solar, especialmente no lado esquerdo das plantas de café, está positivamente correlacionada com o aumento da infestação causada pelo nematoide *Meloidogyne exigua*. Além disso, durante a estação chuvosa, caracterizada por temperaturas mais altas e maior umidade do solo, observou-se um aumento significativo na infestação pelo nematoide. O período de coleta das amostras também se mostrou relevante, com uma associação entre o período seco e uma menor infestação por nematoides. Essas descobertas destacam a importância de considerar fatores climáticos, como exposição solar e estação do ano para um manejo eficaz dos nematoides nas plantações de café.

AGRADECIMENTOS

Gostaríamos de agradecer à Universidade Federal de Lavras (UFLA), ao programa de pós-graduação em Engenharia Agrícola (PPGEA) e ao programa de Pós-Graduação em Fitopatologia (DFP) da UFLA pelo apoio a este estudo, ao Consórcio Embrapa Pesquisa Café pelo financiamento da pesquisa (projeto 10.18.20.041.00.00), ao Conselho Nacional Desenvolvimento Tecnológico (CNPq) (projeto 305953/2020-6), à Fundação Mineira de Amparo à Pesquisa (FAPEMIG) (projetos PPE-00118-22 e BPD-00040-22), à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo

apoio financeiro e à Fundação Mineira de Amparo à Pesquisa (FAPEMIG) pela bolsa de doutorado da terceira autora.

REFERÊNCIAS

BESSA, R. T. Termografia na avaliação da temperatura de mudas de Tagetes erecta cultivadas em diferentes ambientes com e sem hidroretentor. **Monografia** (Graduação em Agronomia) - Centro de Ciências Agrárias, Universidade Federal do Ceará, Fortaleza. p.54, 2021.

MARCUZZO, K. V.; SANTOS, M. A.; JULIATTI, F. C.; MELO, B.; SEVERINO, G. M. Uso de nematicidas no controle de Meloidogyne incognita e M. exigua em cafeeiro, no município de Indianópolis, MG. **Simpósio de pesquisa dos cafés do Brasil**, Poços de Caldas. Brasília: EMBRAPA, v.1, p.260-261. 2000.

PAN, J.; JU, Y.; WANG, X., AND ZHANG, H. Detection of Bursaphelenchus xylophilus infection in Pinus massoniana from hyperspectral data. **Nematology** v.16, n.10, p.1197-1207, 2014.

SANTOS, L.M. DOS; FERRAZ, G.A. E. S.; CARVALHO, M.A. DE F.; TEODORO, S.A.; CAMPOS, A.A.V.; MENICUCCI NETO, P. Use of RPA Images in the Mapping of the Chlorophyll Index of Coffee Plants. **Sustainability**. v.14, n.20, 2022.

TERRA, W.C.; PEREIRA DA SILVA, J.C.; CAMPOS, V.P.; MARIA, S.; SALGADO, L. Root-Knot and Lesion Nematodes in Coffee Seedlings Produced in the State of Minas Gerais, Brazil**. Coffee Science**, v.13, p.178-186. 2018.

UNITED STATES DEPARTMENT OF AGRICULTURE (USDA). Disponível em:< http://usda.mannlib.cornell.edu/MannUsda/viewDocumentInfo.do?documentID=1801> Acesso em: março de 2024.

VIANA, L.A.; ZAMBOLIM, L.; SOUSA, T. V; TOMAZ, D.C. Potential Use of Thermal Camera Coupled in UAV for Culture Monitoring. **Brazilian Journal of Biosystems Engineering** v.12, n.3, p.286-298. 2018.

DESENVOLVIMENTO DE PLATAFORMA MULTISENSOR PORTÁTIL PARA CARACTERIZAÇÃO DE VARIABILIDADE ESPACIAL DO SOLO

Andre Luiz de Freitas Coelho [1]; Daniel Marçal de Queiroz [1]; Eduardo Leonel Bottega [2]; Emanoel Di Tarso dos Santos Sousa [3]; Marcelo Marques Costa [4]

[1]Professor. Viçosa -MG. Depto. de Engenharia de Agrícola, Universidade Federal de Viçosa; [2]Professor. Cachoeira do Sul - RS. Depto. de Engenharia Rural, Universidade Federal de Santa Maria; [3]Professor. Recife - PE. Depto. de Engenharia Agrícola, Universidade Federal Rural de Pernambuco; [4]Professor. Jataí-GO. Instituto de Ciência Agrárias, Universidade Federal de Jataí

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

O mapeamento da condutividade elétrica aparente (CEa) do solo vem sendo utilizado para a caracterização da variabilidade espacial e temporal de áreas agrícolas. A dependência de contato eletrodo-solo, para os sensores por método resistivo, a dependência da CEa com a temperatura e teor de água, a dificuldade de mecanização de lavouras em montanha e o custo de aquisição são fatores que motivam o desenvolvimento de novos sensores de CEa para o mapeamento do solo. Objetivou-se desenvolver uma plataforma multisensor portátil para medição da CEa, temperatura e teor de água do solo, com o georreferenciamento dos pontos de coleta. A plataforma multisensor foi desenvolvida utilizando a placa ESP32-S3, com programa de computador em C++ e operação via dispositivo móvel Android. Circuitos eletrônicos foram desenvolvidos para a medição da CEa, temperatura e teor de água do solo. Um algoritmo foi implementado para detecção do contato eletrodo-solo. Para validação do sensor de CEa, conjunto de resistores foram utilizados para simular solos com CEa entre 0,78 e 122,88 mS.m-1. Em campo, a plataforma multisensor foi utilizada para mapeamento de lavoura de café com 5,0 ha. O sensor de CEa da plataforma multisensor de solo apresentou resultados satisfatórios nos testes realizados em laboratório. A plataforma multisensor de solo detectou variabilidade espacial da condutividade elétrica aparente, temperatura e teor de água do solo na lavoura de café.

PALAVRAS-CHAVE: caracterização físico-química; variabilidade espacial e temporal; zonas de manejo

ABSTRACT

The mapping of soil apparent electrical conductivity (ECa) has been used to characterize the spatial and temporal variability of agricultural areas. The electrode-soil contact dependency for sensors using the resistive method, the dependency of ECa on temperature and moisture, the difficulty of mechanizing crops in mountains terrain, and the acquisition cost are factors driving the development of new sensors for soil mapping. The objective of this work was to develop a portable multisensor platform for measuring soil ECa, temperature, and moisture, with georeferencing of collection points. The multisensor platform was developed using the ESP32-S3 board, with computer program written in C++ and operation via an Android mobile device. Electronic circuits were developed for measuring soil ECa, temperature, and moisture. An algorithm was implemented for detecting electrode-soil contact. To validate the ECa sensor, a set of resistors was used to simulate soils with ECa ranging from 0.78 to 122.88 mS.m-1. In the field, the multisensor platform was used to map a 5.0 ha coffee plantation. The ECa sensor of the multisensor soil platform yielded satisfactory results in the laboratory tests conducted. The multisensor platform detected spatial variability of soil ECa, temperature, and moisture in the coffee plantation.

KEYWORDS: ;

INTRODUÇÃO

Fatores como aumento da população mundial, que resulta em maior demanda por alimentos, escassez de insumos como água e fertilizantes e a necessidade de uma produção agrícola sustentável têm motivado a adoção da Agricultura de Precisão em todo o mundo. Essa técnica envolve dentre outras atividades, a geração e análise de mapas que descrevam a variabilidade espacial e temporal dos atributos relacionados ao solo e/ou às plantas que influenciam a produtividade. Os mapas de solo têm sido gerados pela técnica de amostragem do solo e posterior análise em laboratório. Mapas fidedignos podem requerer amostragens densa, resultando em maiores demandas de recursos humanos e financeiros (MAHMOOD; HOOGMOED; VAN HENTEN, 2012, QUEIROZ et al., 2017). Alternativamente, pode-se gerar mapas de propriedades elétricas do solo com dados que podem ser adquiridos em amostragem densa, porém demandando menos recursos humanos e financeiros. As propriedades elétricas do solo geralmente estão relacionadas aos atributos físicos e químicos do solo de interesse agronômico. A partir desse tipo de análise é possível fazer análises das variabilidades espaciais e temporais de atributos do solo e definir zonas de manejo. Dentre os dados que podem ser usados para gerar as zonas de manejo destaca-se a condutividade elétrica aparente (CEa) do solo, visto a sua correlação com atributos de textura, nutrientes, matéria orgânica, dentre outros (DENG et al., 2020, STABLER et al., 2015). A CEa também é influenciada pelo teor de água (umidade) e temperatura do solo (MAHMOOD; HOOGMOED; VAN HENTEN, 2012). Assim, é recomendável a medição desses dois atributos durante a medição da CEa. Os equipamentos para medição da CEa adotam, principalmente, o método da resistividade ou o método da indução eletromagnética. O primeiro tem a vantagem de ser método direto, dispensando calibração e ter menor custo. Sua desvantagem é a necessidade de contato perfeito entre os eletrodos que compõem o sensor e o solo (PEDRERA- PARRILLA et al., 2016). Já o segundo método não tem contato direto com o solo, mas requer calibrações diárias e apresentam maior custo de aquisição. A ausência de contato perfeito eletrodo-solo ocasiona a medição de valores errados de CEa. Contudo, tal desvantagem pode ser eliminada por meio de algoritmos que analisam os sinais elétricos utilizados no cálculo da CEa (SOUSA et al., 2020). Para ambos os métodos, os equipamentos disponíveis no mercado podem apresentar custos de aquisição que inviabilizam o seu uso por agricultores com menor capacidade de investimento em tecnologias e em áreas montanhosas devido à dificuldade de mecanização.

OBJETIVOS

No presente trabalho objetivou-se desenvolver uma plataforma multisensor portátil para medição da CEa, temperatura e teor de água do solo, além de georefenciar o ponto de medição.

MATERIAL E MÉTODOS

Desenvolvimento da plataforma multisensor

Para o desenvolvimento da plataforma multisensor de solo adotou-se como base os desenvolvimentos apresentados por Queiroz et al. (2016, 2017, 2020) e Sousa et al. (2020, 2023). A placa de desenvolvimento utilizada foi a ESP32-S3, com programa de computador desenvolvido em linguagem C++. A operação se deu por aplicativo executado por dispositivo portátil (tablet) Android, que se comunicou com a ESP32-S3 por protocolo Bluetooth Low Energy. O receptor do sistema de navegação global por satélite (GNSS) do dispositivo Android foi utilizado para o georreferenciamento dos pontos de coleta. Um carregador portátil de 5 V e 10 Ah foi utilizado para fornecer energia elétrica para a ESP32-S3. O sensor de CEa foi desenvolvido com base na matriz de Wenner, contendo circuito eletrônico para gerar sinal elétrico bipolar, medir corrente elétrica do sinal bipolar, medir tensão em cada eletrodo intermediário, transformar sinal bipolar em unipolar e ler sinais elétricos. A primeira parte do circuito eletrônico foi responsável por gerar sinal em formato de onda quadrada, amplitude -9 a 9 V, a partir de sinal PWM gerado pela ESP32 e utilizando o amplificador operacional LM741. Esse sinal foi aplicado no solo por um eletrodo denominado E1,

retornando pelo eletrodo E4 (Figura 1). A frequência do sinal é um dado de entrada definido pelo usuário via aplicativo desenvolvido para dispositivo Android. O medidor de corrente elétrica do sinal bipolar aplicado no solo constituiu em resistor shunt 180 ohm e amplificador operacional TL072 em configuração diferencial. Para medir a tensão dos eletrodos intermediários (eletrodo E2 e E3 da Figura 1) utilizou-se o amplificador operacional TL072 em configuração com ganho unitário. Um circuito com base no amplificador operacional MCP 6002 foi utilizado para transformar os sinais gerados pelos circuitos medidor de corrente elétrica e tensão no eletrodo intermediário, que são bipolares, em sinal unipolar com amplitude 0,0 a 3,3 V. Os sinais elétricos unipolares foram lidos pela ESP32 com auxílio do conversor ADC externo ADS1015 com resolução 12 bit. A taxa de amostragem adotada foi oito vezes a frequência do sinal aplicado ao solo. Um conjunto com seis baterias recarregáveis modelo 18650 3,7 V 2200 mAh foi utilizado para fornecer energia elétrica para o circuito eletrônico em tensão simétrica (12 V e -12 V).

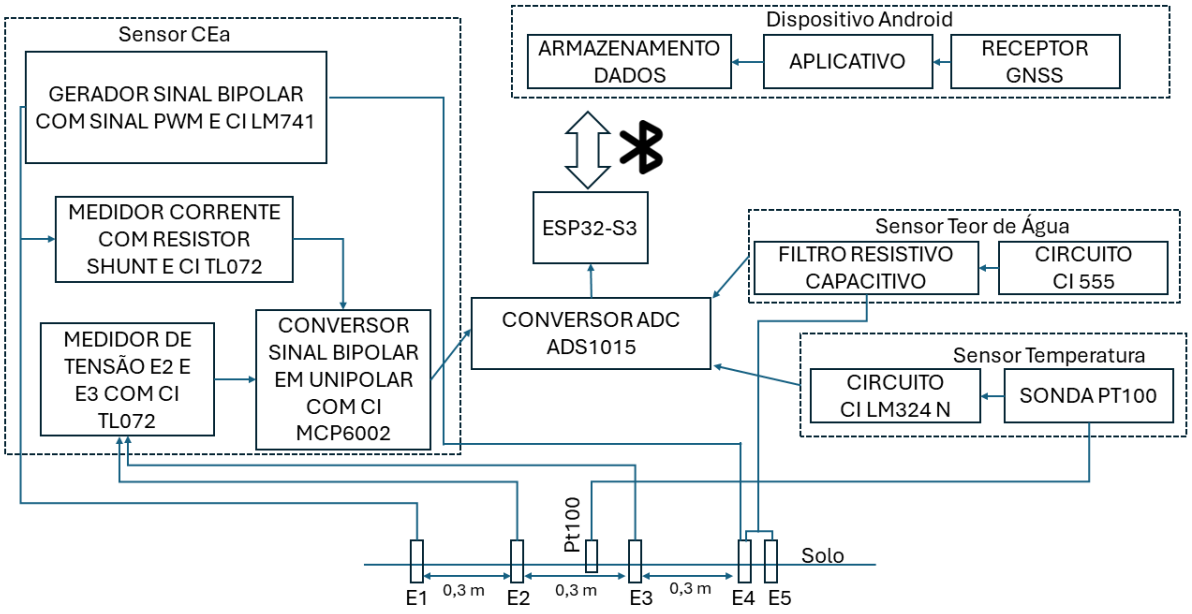


FIGURA 1. Esquema da plataforma multisensor de solo com sensor de condutividade elétrica aparente (CEa), temperatura e teor de água do solo, com o dispositivo Android para operação. ADC = conversor analógico-digital; CI = circuito integrado; E1 a E5 = eletrodos; PWM = modulação pela largura de pulso.

No programa de computador, o sinal unipolar foi reconvertido em sinal bipolar utilizando equação matemática obtida experimentalmente. Ainda no programa, calculou-se a tensão absoluta média dos sinais gerados no resistor shunt e nos eletrodos intermediários. A partir da queda de tensão no resistor shunt calculou-se a corrente elétrica do sinal elétrico aplicado ao solo. A partir da tensão em cada eletrodo intermediário (Eletrodos E2 e E3), em relação ao sinal de referência GND, calculou-se a diferença de tensão nos referidos eletrodos causada pelo sinal elétrico transmitido pelo solo. A CEa foi calculada pela Equação 1 considerando espaçamento entre hastes de 0,3 m.

$$CEa = \frac{i}{2\pi a V} \qquad \text{Eq. (6)}$$

em que, CEa é a condutividade elétrica aparente (em $mS.m^{-1}$), i é a corrente do sinal elétrico aplicado ao solo (em A), a é a distância entre eletrodos (em m), e V é a diferença de potencial nos eletrodos intermediários (em V).

Os sinais elétricos referentes à corrente elétrica, tensão em cada eletrodo intermediário e diferença de tensão entre os eletrodos intermediários foram submetidos ao algoritmo de análise de detecção de

contato eletrodo - solo. A hipótese utilizada no desenvolvimento foi: se o sinal elétrico emitido no solo tem forma de onda quadrada e foi simétrico, os quatro sinais elétricos lidos deveriam apresentar características similares (SOUSA et al., 2021). Cada sinal elétrico foi analisado dividindo-o em parte positiva (tensão maior que zero) e parte negativa (tensão menor ou igual a zero), para contabilização do número de medições e a tensão média em cada parte. A razão entre número de medições na parte negativa e positiva próximo de 1,0 indicou que o sinal se aproximou da forma de onda quadrada. A razão entre a tensão média da parte negativa e a positiva próximo de -1,0 indicou simetria do sinal elétrico. Para razão de número de medições positivas e de negativas adotou-se como aceitável o intervalo 0,5 a 1,5. Já para a razão de tensões adotou-se como aceitável - 0,25 a -1,75. Ambos foram obtidos após análise de sinais obtidos em medições com resistor e em campo. Foi considerado ausência de contato eletrodo solo se um dos quatro sinais elétricos apresentaram razões fora do intervalo aceitável.

O circuito do sensor de teor de água do solo foi desenvolvido com base no princípio capacitivo. No circuito eletrônico, um circuito integrado 555 foi utilizado para gerar um sinal elétrico. Dois eletrodos (E4 e E5 na Figura 1) possibilitaram que o solo atuasse como um capacitor em um filtro resistivo-capacitivo. O sinal elétrico medido na saída do circuito (SIG_m na Figura 2a) foi relacionado com o teor de água gravimétrico do solo a partir de equação polinomial obtida experimentalmente (SOUSA et al, 2023). Para o sensor de temperatura do solo utilizou uma sonda Pt100 de três fios, diâmetro 6,35 e comprimento 100 mm, conectada a um circuito eletrônico com base no amplificador operacional LM324N (Figura 1). O sinal elétrico medido da saída do circuito (SIG_t na Figura 2b) foi relacionado com a temperatura a partir de equação linear obtida experimentalmente. Um módulo com dois relés eletromecânicos possibilitou a emissão dos sinais utilizados para medição da CEa e teor de água do solo em instantes de tempo distintos para evitar que uma medição interferisse na outra.

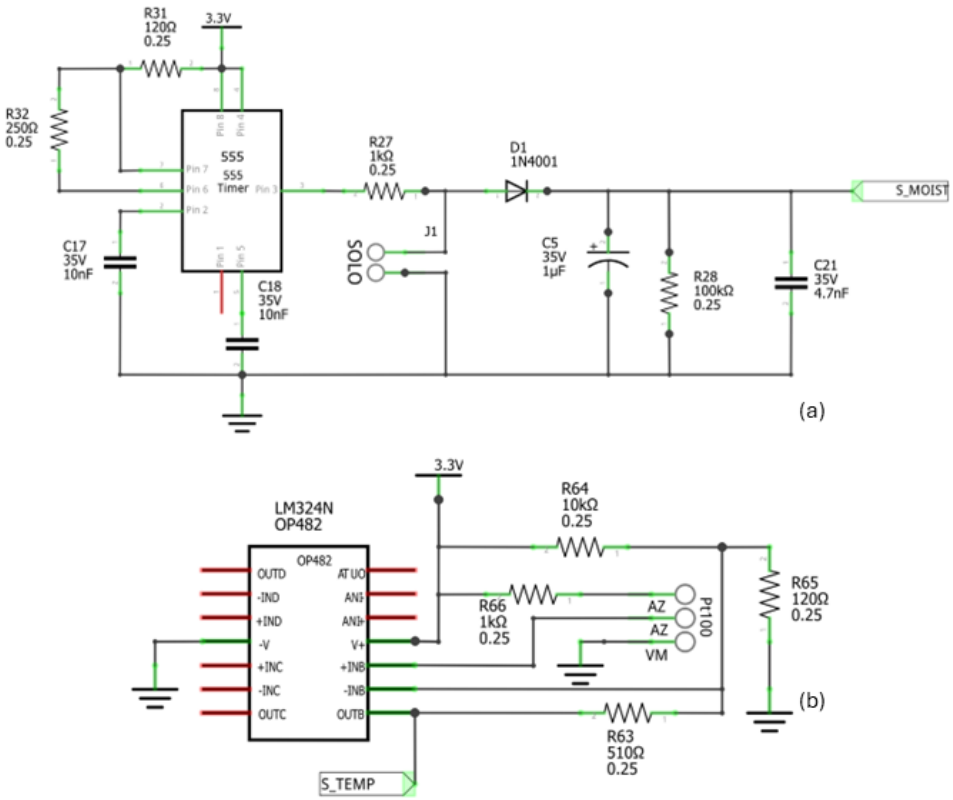


FIGURA 2. Circuitos eletrônicos dos sensores de (a) teor de água e (b) temperatura contido na plataforma multisensor de solo. SIG_m e SIG_t são os sinais elétricos de saída dos circuitos eletrônicos do sensor de teor de água e temperatura, respectivamente.

Testes Experimentais

O sensor de CEa foi validado, em laboratório, utilizando conjunto com três resistores conectados em série, simulando solos com CEa entre 0,78 e 122,88 $mS.m^{-1}$. A partir da resistência dos resistores e aplicando a Lei de Ohm calculou-se a CEa teórica para cada conjunto de resistores. O conjunto de resistores foi conectado nos quatro eletrodos e a CEa medida utilizando a plataforma multisensor. O procedimento foi repetido para frequências de sinais elétricos 3 Hz, 10 Hz, 25 Hz, 50 Hz, 75 e 100 Hz, com cinco repetições cada. Para a validação, calculou-se o desvio relativo e o desvio percentual entre o valor de CEa teórico e a média dos valores medidos em cada uma das frequências. Em campo, testou-se a plataforma multisensor no mapeamento do solo em uma lavoura de café de 5,0 ha, localizada na microrregião de Viçosa, Minas Gerais, Brasil. O solo da lavoura é caracterizao como Argissolo Vermelho-Amarelo. A CEa, temperatura e teor de água do solo foi medida em pontos amostrais dispostos em grade irregular. Para cada ponto amostral considerou-se o valor médio obtido de medições realizadas em um círculo de raio 1,0 m em torno do ponto de medição. Cada ponto amostral teve, no mínimo, quatro medições. Só foram aceitas medições quando o sensor indicava a existência de contato eletrodo-solo. Foi realizada a remoção das medições discrepantes em duas etapas: i) valores extremos (CEa > 40 $mS.m^{-1}$; teor de água < 10%) e ii) valores fora do intervalo média ± 2,5 vezes desvio padrão (TAYLOR et al., 2007). Para a CEa, fez-se a análises excluindo as medições classificadas pelo algoritmo como ausência de contato eletrodo-solo. Para geração dos mapas de variabilidade espacial utilizou-se interpolação por aprendizado de máquinas do plugin SmartMap para QGIS (PEREIRA et al., 2022).

RESULTADOS E DISCUSSÃO

O desvio entre a média dos valores medidos pelo sensor de CEa e o valor teórico variou entre -0,20 $mS.m^{-1}$ (desvio percentual de -0,57%) e 0,45 $mS.m^{-1}$ (desvio percentual de 0,70%). O maior desvio percentual foi 16,03% (desvio relativo 0,13 $mS.m^{-1}$), para o valor de CEa teórico de 0,78 $mS.m^{-1}$ (Tabela 1). Os maiores desvios relativos ocorreram em condições de menores valores de CEa, característico de solos com baixa teor de água. Em análise similar Queiroz et al. (2020) também obtiveram maiores desvios relativos à medida que a CEa diminui. Para tal situação, a diferença de potencial nos eletrodos intermediários reduz, indicando que o circuito eletrônico é impreciso nessa situação. Queiroz et al. (2020) relataram que a variabilidade local do solo pode ser maior que os desvios relativos obtidos, podendo tais desvios serem considerados aceitáveis. Assim como em Queiroz et al. (2020), no presente trabalho observou-se que o sensor de CEa tem precisão similar para as diferentes frequências do sinal elétrico emitido no solo.

TABELA 1. Validação do sensor de condutividade elétrica aparente utilizando conjunto de resistores, para diferentes frequências de sinal elétrico emitido no solo, com desvio relativo (DR) e desvio percentual (DP).

Resistor (ohm)	Valor Teórico de CEa ($mS.m^{-1}$)	CEa medida pela plataforma multisensor ($mS.m^{-1}$)							DR	DP (%)
		3 Hz	10 Hz	25 Hz	50 Hz	75 Hz	100 Hz	Média		
4,70	112,88	113,68	110,83	113,53	111,46	115,3	112,23	112,84	-0,04	0,04%
8,20	64,70	64,93	64,3	64,71	65,2	65,4	66,36	65,15	0,45	0,70%
15,00	35,37	35,00	34,8	35	35,7	35,7	34,8	35,17	-0,20	-0,57%
33,00	16,08	16,26	16,26	15,77	16,23	16,2	16,01	16,12	0,04	0,26%
47,00	11,29	11,66	11,6	11,7	11,7	11,73	11,67	11,68	0,39	3,42%

82,00	6,47	6,80	6,86	6,9	6,76	6,7	6,9	6,82	0,35	5,41%
220,00	2,41	2,63	2,6	2,63	2,63	2,53	2,53	2,59	0,18	7,54%
470,00	1,13	1,30	1,3	1,27	1,3	1,33	1,3	1,30	0,17	15,04%
680,00	0,78	0,90	0,9	0,93	0,9	0,9	0,9	0,91	0,13	16,03%

Na lavoura de café foram realizadas 712 medições em 103 pontos amostrais. Para CEa, 123 (17,2%) medições foram removidas porque foram classificados pelo algoritmo como ausência de contato eletrodo-solo. A área apresentou variabilidade espacial, com regiões contendo CEa inferior a 6,8 $mS.m^{-1}$ e regiões com CEA superior a 15,42 $mS.m^{-1}$(Figura 3).

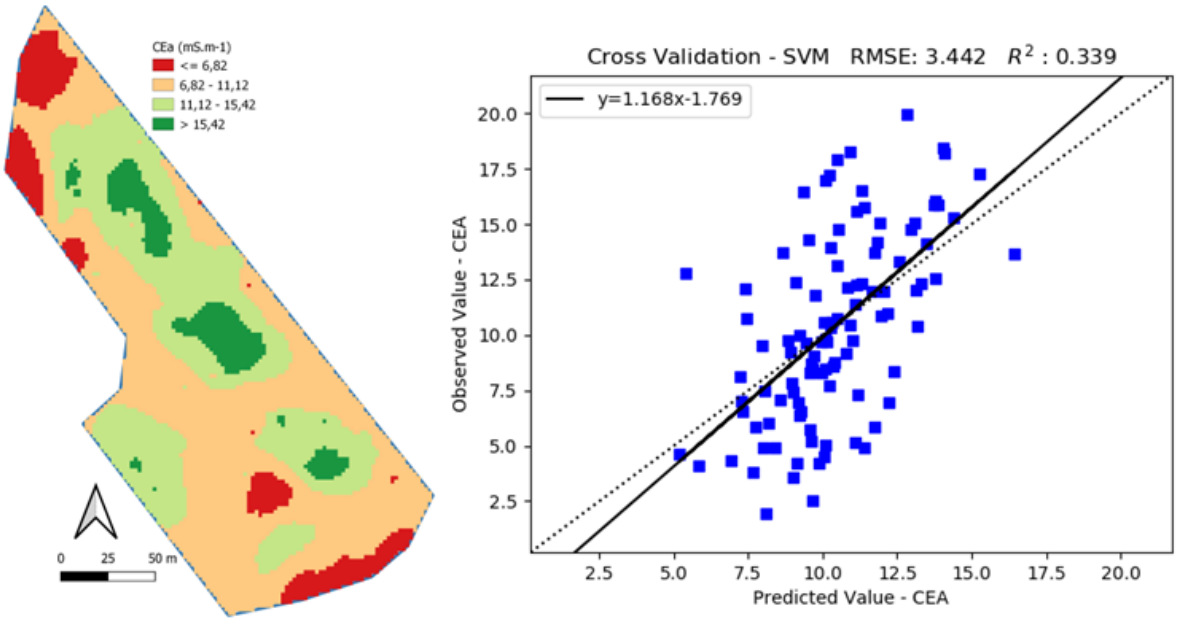


FIGURA 3. Mapa de condutividade elétrica aparente de solo (CEa) e respectivo gráfico de validação cruzada de lavoura de café obtido com dados gerados pela plataforma multisensor.

As regiões com maiores e menores valores CEa (Figura 3) coincidiram com as regiões de maiores e menores valores de teor de água do solo (Figura 4), respectivamente. Além dos fatores textura de solo, nutrientes, matéria orgânica, a variação na CEa também pode estar relacionada à variação do teor de água no solo (DENG et al., 2020 MAHMOOD; HOOGMOED; VAN HENTEN, 2012). Assim, pode ser que o solo da lavoura de café mapeada seja homogêneo quanto às características físicas e químicas, uma vez que as variações de CEa acontecem de forma similar às variações de teor de água.

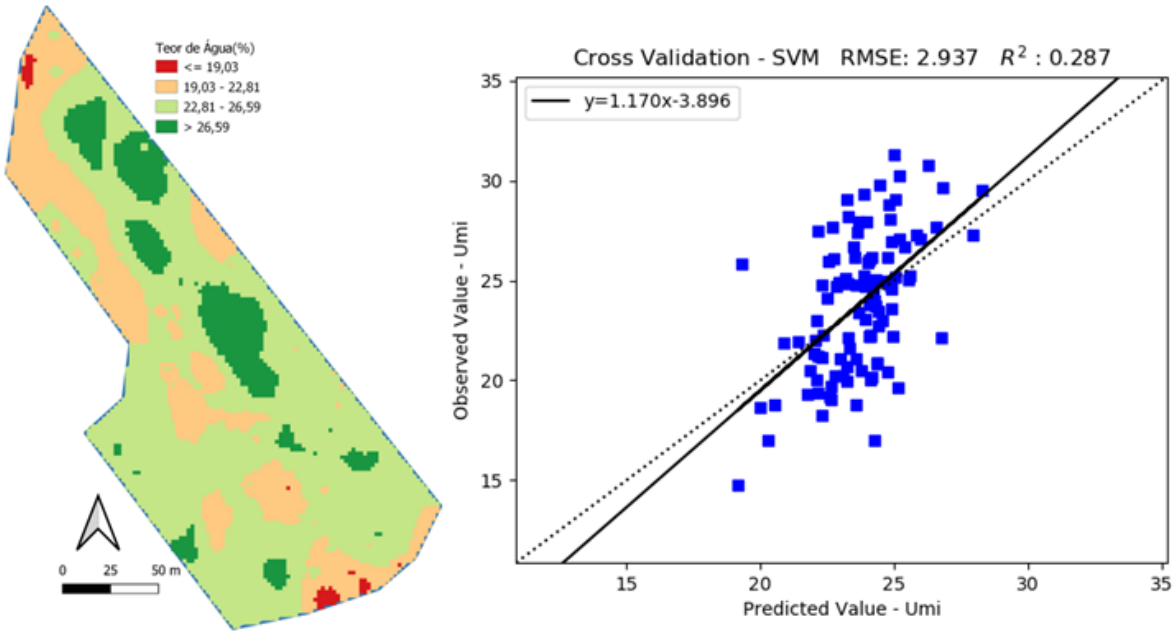


FIGURA 4. Mapa de teor de água (umidade) do solo e respectivo gráfico de validação cruzada de lavoura de café obtido com dados gerados pela plataforma multisensor.

A variação de temperatura do solo ocorreu, principalmente, devido aos horários de medição em cada região (Figura 5). Além disso, algumas regiões das bordas continham árvores que sombreavam o solo em determinados períodos. Devido à influência da temperatura na condutividade elétrica, Corwin e Lesch (2005) recomendaram que seja realizado ajuste na CEa para temperatura de 25 ºC, caso a amplitude de variação ultrapasse 10 ºC. Como a amplitude de variação observada no mapa foi inferior a esse limiar, não foi necessário realizar tal correção.

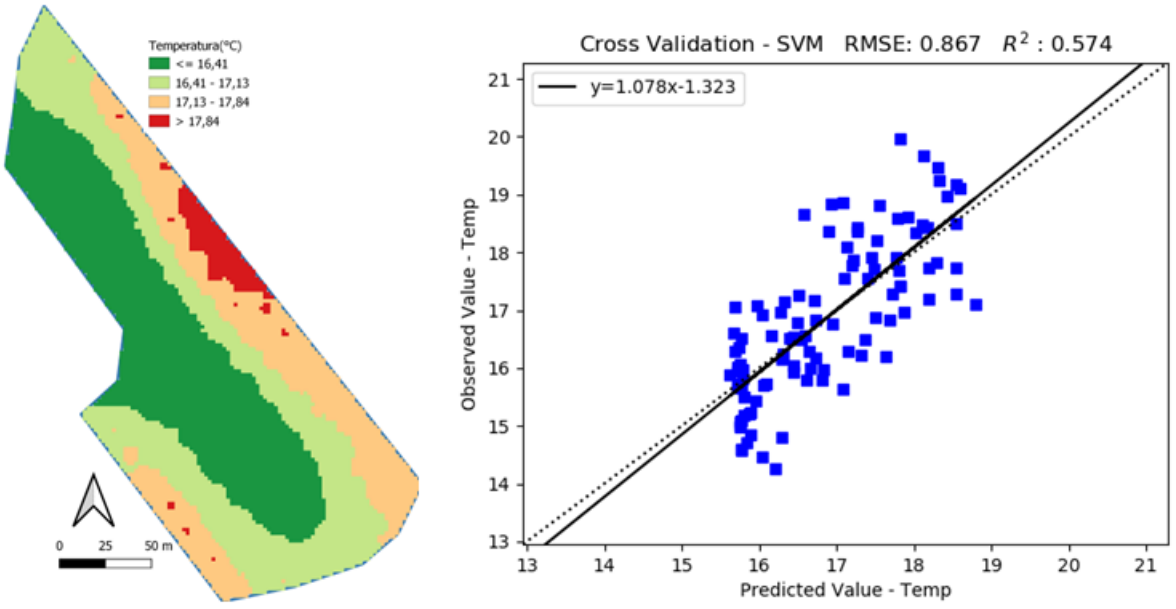


FIGURA 5. Mapa de temperatura do solo e respectivo gráfico de validação cruzada de lavoura de café obtido com dados gerados pela plataforma multisensor.

CONCLUSÃO

O sensor de CEa da plataforma multisensor de solo apresentou resultados satisfatórios nos testes realizados em laboratório. A plataforma multisensor de solo detectou variabilidade espacial da condutividade elétrica aparente, temperatura e teor de água do solo na lavoura de café de 5,0 ha.

AGRADECIMENTOS

Os autores do presente trabalho agradecem ao Conselho Nacional de Pesquisa e Desenvolvimento (CNPq) pelo apoio financeiro para a realização da pesquisa por meio do Processo: 404374/2021-2, da chamada CNPq/MCTI/FNDCT No 18/2021, Título: "Desenvolvimento de um sistema inteligente para caracterização da variabilidade espacial do solo em agricultura de precisão"

REFERÊNCIAS

CORWIN, D. L.; LESCH, S. M. Characterizing soil spatial variability with apparent soil electrical conductivity: I. Survey protocols. **Computers and electronics in agriculture**, v. 46, n. 1-3, p. 103-133, 2005.

DENG, X. *et al.* A method of electrical conductivity compensation in a low-cost soil moisture sensing measurement based on capacitance. **Measurement**, v. 150, n. 1, p. 107052-107062, 2020.

MAHMOOD, H. S.; HOOGMOED, W. B.; VAN HENTEN, E. J. Sensor data fusion to predict multiple soil properties. **Precision Agriculture**, v. 13, n. 1, p. 628-645, 2012

PEDRERA-PARRILLA, A. *et al*. Apparent electrical conductivity measurements in an olive orchard under wet and dry soil conditions: significance for clay and soil water content mapping. **Precision Agriculture**, v.17, n.5, p. 531-545, 2016.

PEREIRA, G. W. *et al*. Smart-Map: An Open-Source QGIS Plugin for Digital Mapping Using Machine Learning Techniques and Ordinary Kriging. **Agronomy**, v.12, n.6, p.1350, 2022.

QUEIROZ, D. M. *et al*. Development and testing of a low-cost portable apparent soil electrical conductivity sensor using a Beaglebone Black. *In:* **2017 ASABE Annual International Meeting**. St. Joseph: ASABE, 2017. (Paper Number 1700062).

QUEIROZ, D. M. *et al*. Development and testing of a low-cost portable apparent soil electrical conductivity sensor using a Beaglebone Black. **Applied Engineering in Agriculture**, v. 36, n. 3, p. 341-355, 2020.

QUEIROZ, D. M.; LEE, W. S.; SCHUELLER, J. K. Development of a portable soil sensor system using BeagleBone Black. *In:* **2016 ASABE Annual International Meeting**. St. Joseph: ASABE, 2016. (Paper Number 162447581).

SOUSA, E. D. T dos S. *et al*. Development of signal analysis algorithm for apparent soil electrical conductivity sensor, **Biosystems Engineering**, v.211, n.1, p. 183-191, 2021

SOUSA, E. D. T dos S. *et a*l. Development of a portable multisensor platform for soil mapping, **Revista Ciência Agronômica** v.54, e20217886, 2023, 2021

STADLER, A. *et al*. Quantifying the effects of soil variability on crop growth using apparent soil electrical conductivity measurements. **European Journal of Agronomy**, v. 64, n. 1, p. 8-20, 2015.

TAYLOR, J. A., MCBRATNEY, A. B., & WHELAN, B. M. Establishing management classes for broadacre agricultural production. **Agronomy Journal**, v.99, n.5, p.1366-1376, 2007.

PREDIÇÃO DE PRODUTIVIDADE DA CANA-DE-AÇÚCAR A PARTIR DE IMAGENS SAR E MULTIESPECTRAIS EM ALTA RESOLUÇÃO ESPACIAL

David Lopes Lima [1,3]; José Paulo Molin [2]; Ricardo Canal Filho [3]; Eudocio Rafael Otavio da Silva [3]
[1]Bolsista. R. Pio XI, 1500 - Alto da Lapa, São Paulo - SP, 05468-901. Fundação de Amparo à Pesquisa do Estado de São Paulo; [2]Docente. Av. Pádua Dias, 11 - Agronomia, Piracicaba - SP, 13418-900. Escola Superior de Agricultura Luiz de Queiroz; [3]Discente. Av. Pádua Dias, 11 - Agronomia, Piracicaba - SP, 13418-900. Escola Superior de Agricultura Luiz de Queiroz

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
O sensoriamento remoto tem sido explorado no mapeamento da produtividade de lavouras, por permitir a identificação de variabilidade de forma não destrutiva e em alta resolução espacial e temporal. O presente trabalho teve como objetivo desenvolver modelos preditivos de produtividade da cana-de-açúcar, produzidos por algoritmos de aprendizado de máquina supervisionado, por meio de imagens satelitais e dados de monitor de produtividade em alta resolução espacial. Para isto, foram utilizados o índice de vegetação *Vegetation Optical Depth* (VOD) e banda C do sensor *Synthetic Aperture Radar* (C-SAR), que não sofrem com oscilações climáticas, e os índices *Normalized Difference Vegetation Index* (NDVI) e *Green-Red Vegetation Index* (GRVI) conhecidos por apresentarem alta correlação com o conteúdo de água, biomassa das plantas e taxa fotossintética. Os índices NDVI e GRVI foram capazes de originar modelos preditivos com coeficiente de determinação (R^2) acima de 0,95, raiz do erro quadrático médio (RMSE) abaixo de 6,55 Mg ha^{-1} e *Index of Agreement Modified* (dmod) igual a 0,99. No campo das micro-ondas, a banda C-SAR apresentou R^2 = 0,85, RMSE = 12,63 Mg ha^{-1} e dmod = 0,96. Portanto, foi possível obter modelos preditivos de produtividade em alta resolução espacial em canaviais antes da colheita, sendo as imagens SAR e multiespectrais alternativas promissoras na ausência de monitores de produtividade.

PALAVRAS-CHAVE: Mapas de produtividade; Aprendizado de máquina; Índice de vegetação

ABSTRACT
Remote sensing has been explored in mapping crop yield, as it allows the identification of variability in a non-destructive way and at high spatial and temporal resolution. The present work aimed to develop predictive sugarcane yield models, produced by supervised machine learning algorithms, using satellite images and productivity monitor data at high spatial resolution. For this, the vegetation index *Vegetation Optical Depth* (VOD) and band C of the *Synthetic Aperture Radar* (C-SAR) sensor, which do not suffer from climate oscillations, and the Normalized Difference Vegetation Index (NDVI) and *Green-Red Vegetation Index* (GRVI) were used, known to have a high correlation with water content, plant biomass and photosynthetic rate. The NDVI and GRVI indices were able to generate predictive models with coefficient of determination (R^2) above 0.95, root mean-square error (RMSE) below 6.55 Mg ha^{-1} and *Index of Modified Agreement* (dmod) equal to 0.99. In the microwave field, the C-SAR band presented R^2 = 0.85, RMSE = 12.63 Mg ha^{-1} and dmod = 0.96. Therefore, it was possible to obtain predictive yield models at high spatial resolution in sugarcane fields before harvesting, with SAR and multispectral images being promising alternatives in the absence of productivity monitors.

KEYWORDS: ;;

INTRODUÇÃO

A cana-de-açúcar (*Saccharum officinarum* L.) demonstra grande relevância na economia brasileira e, em especial, no estado de São Paulo. Segundo a Companhia Nacional de Abastecimento (CONAB, 2023), a produção de cana-de-açúcar, na safra 2022/23, totalizou 610,13 milhões de toneladas. Nesse sentido, nos últimos anos, tem-se elevado a adoção de ferramentas de análise de dados e de práticas de Agricultura de Precisão (AP) no setor sucroenergético visando ao aumento de produtividade e otimização de recursos (MALDANER & MOLIN, 2020). No entanto, apesar da difusão destas técnicas no cultivo da cana-de-açúcar no Brasil ter crescido, sua aplicação ainda é incipiente (MOZAMBANI, 2021).

Os mapas de produtividade são um componente essencial à implementação das práticas de AP, por serem considerados a camada mais importante para o diagnóstico e entendimento da variabilidade espacial e temporal das culturas (MOMIN et al., 2019; SANCHES et al., 2019). No entanto, os dados de produtividade da cana-de-açúcar, obtidos diretamente pelos monitores embarcados em colhedoras, enfrentam desafios tecnológicos, econômicos e logísticos nos canaviais (CANATA; MOLIN; SOUSA, 2019). Sendo assim, o sensoriamento remoto (SR) pode representar uma solução ao mapeamento e caracterização da variabilidade espacial e temporal da produtividade na cana-de-açúcar (MALDANER & MOLIN, 2020).

Usualmente, na AP, são utilizados índices de vegetação (IVs) obtidos por meio de imagens multiespectrais com base em taxas de reflectância, como o *Normalized Difference Vegetation Index* (NDVI) (ROUSE et al., 1974), *Green-Red Vegetation Index* (GRVI) (TUCKER, 1979). No entanto, novas abordagens de IVs têm sido realizadas principalmente no campo das micro-ondas com o uso de sensores imageadores *Synthetic Aperture Radar* (SAR) (SANTOS et al., 2023; ZHU et al., 2023; EL HAJJ et al., 2019), que sofre menor interferência de nuvens (KONINGS et al., 2019). Dentre essas abordagens, o *Vegetation Optical Depth* (VOD) tem se destacado na estimativa de produtividade das culturas agrícolas devido à sua forte correlação com o conteúdo de água e biomassa. Sendo assim, mais especificamente na cultura da cana-de-açúcar, este IV é uma ferramenta promissora em estudos de avaliação e predição de produtividade, visto que o rendimento desta cultura é diretamente dependente da biomassa, diferentemente daquelas cujo rendimento é medido pela quantidade de grãos e frutos ou peso de pluma (ZHU et al., 2023; CHAPARRO et al., 2018).

OBJETIVOS

O presente trabalho teve como objetivo desenvolver modelos preditivos de produtividade da cana-de-açúcar, produzidos por algoritmos de aprendizado de máquina supervisionado, por meio de imagens satelitais e dados de colheita em alta resolução espacial, a fim de escalar o monitoramento espaço-temporal de canaviais.

MATERIAL E MÉTODOS

O estudo contemplou dados de colheita de duas lavouras comerciais de cana-de-açúcar localizadas no estado de São Paulo (SP), totalizando 310 ha de soqueira de segundo e terceiro corte colhidos em junho e julho de 2021. A obtenção dos dados de colheita da cana-de-açúcar foi realizada a partir de uma abordagem que consiste na coleta de dados de produtividade baseados na pressão hidráulica no sistema picador, composto por dois motores hidráulicos que acionam um par de tambores picadores, com lâminas que cortam os colmos de cana-de-açúcar em toletes. Dessa forma, a mensuração assume que a potência necessária para cortar a cana-de-açúcar é proporcional à taxa de fluxo de massa de cana colhida nos picadores (MALDANER; CANATA; MOLIN, 2022). Assim, os dados de produtividade da safra de cana-de-açúcar foram obtidos por meio de monitores de produtividade embarcados em colhedoras, que registraram os dados em uma frequência média de 0,20 Hz. Posteriormente, foram filtrados a fim de remover dados ruidosos para que se obtenha um banco de dados de qualidade.

O conjunto de dados filtrado foi submetido à análise geoestatística por meio do software VESPER 1.6 (Variogram Estimation and Spatial Prediction with Error) (MINASNY et al., 2005). Nesta etapa, ocorreu o ajuste do semivariograma teórico e posterior análise dos parâmetros variográficos, tais como o efeito pepita, patamar e alcance (WU et al., 2022a). Na validação cruzada, os parâmetros de desempenho utilizados foram o coeficiente de determinação (R^2) e raiz do erro quadrático médio (RMSE). Posteriormente, os dados foram interpolados por krigagem ordinária, a fim de gerarem os mapas de superfície da produtividade da cana-de-açúcar com resolução espacial de 10 m (WU et al., 2022b) .

As imagens SAR foram obtidas a partir do satélite Sentinel-1, que possui resolução espacial de 10 m e resolução temporal de 12 dias na América do Sul. As imagens multiespectrais foram obtidas pelo sensor *Multispectral Imager* (MSI) do satélite Sentinel-2, com resolução espacial de 10 m e temporal de 5 dias. Realizou-se o tratamento, seleção e processamento de 21 imagens no período de junho a dezembro de 2020 (14 imagens do Sentinel-1 e 07 imagens do Sentinel-2), juntamente a 24 imagens no período de janeiro a agosto de 2021 (16 imagens do Sentinel-1 e 08 imagens do Sentinel-2) em ambiente virtual do *Google Earth Engine* (GEE), em linguagem de programação *Javascript*.

Foram selecionadas duas imagens SAR por mês (primeira quinzena - imagem t1; segunda quinzena - imagem t2) durante a safra, sendo formadas imagens compostas mensais por meio da função "diferença" incluída no GEE (ZHU et al., 2023). Esta escolha de imagens ocorreu em razão do índice VOD, que necessita considerar nulo o retroespalhamento da vegetação. Dessa forma, é realizada uma composição de duas imagens para gerar apenas uma.

O VOD foi obtido pela inversão do *water cloud model* (WCM), que simula o dossel da vegetação como uma nuvem de água cujas gotas são mantidas no lugar pela vegetação. O WCM é expresso pelo retroespalhamento total da vegetação, resultado da soma do espalhamento direto da vegetação, retroespalhamento direto da superfície do solo atenuado pelo dossel e retroespalhamento duplo entre a superfície nua do solo e o dossel da vegetação (ZHU et al., 2023), descritos nas equações (1) e (2), respectivamente.

$\sigma^0_{total} = \sigma^0_{vegetação} + ?^2\ \sigma^0_{solo}$ (1)

$?^2 = e^{?2\ (??? / \cos ?)}$ (2)

Em que, ?: ângulo de incidência SAR; T^2: atenuação bidirecional; σ^0: retroespalhamento.

Considerando que as características da vegetação são constantes entre as imagens t1 e t2 ($\Delta\sigma^0_{vegetação,\ t2?t1} = \sigma^0_{vegetação,\ t2} - \sigma^0_{vegetação,\ t1} = 0$), desprezando-se $\sigma^0_{vegetação}$ e assumindo que $\Delta\sigma^0_{solo}$ e $\Delta\sigma^0_{total}$ são conhecidos em t1 e t2, pode-se calcular o VOD pela equação (3) (EL HAJJ et al., 2019).

$VOD = (? \cos ? / 2) \ln (\Delta\sigma^0_{total,\ t2?t1} / \Delta\sigma^0_{solo,\ t2?t1})$ (3)

Para a estimativa da contribuição do solo (σ^0_{solo}) foi considerado que o solo subjacente tem as mesmas propriedades (umidade e rugosidade) que o solo das áreas agrícolas de cana-de-açúcar analisadas. Dessa forma, o critério utilizado para identificação de áreas com solo descoberto ou coberto por vegetação espaçada foi o NDVI estar abaixo de 0,30 (EL HAJJ et al., 2019).

Por meio de imagens adquiridas do Sentinel-2 em datas próximas às datas das imagens t1 e t2, foram identificados os pixels com baixo NDVI, a fim que o σ^0_{solo} pudesse ser obtido pela média do retroespalhamento dessas áreas nas imagens t1 e t2. Com isso, os dados de retroespalhamento das imagens compostas mensais processadas e ortorretificadas foram derivados em dados do VOD em ambiente GEE por meio da equação (3).

Utilizando o Sistema de Informação Geográfica (SIG) QGIS 3.22 (Open Source Geospatial Foundation, Beaverton, EUA), foram realizados processos de vetorização das imagens obtidas no ambiente GEE e união de todas as informações em arquivos *comma separated values* (CSV), a fim que elas pudessem ser utilizadas na modelagem de produtividade realizada na plataforma *Jupiter notebook* em linguagem de programação *Python* (KLUYVER et al., 2016).

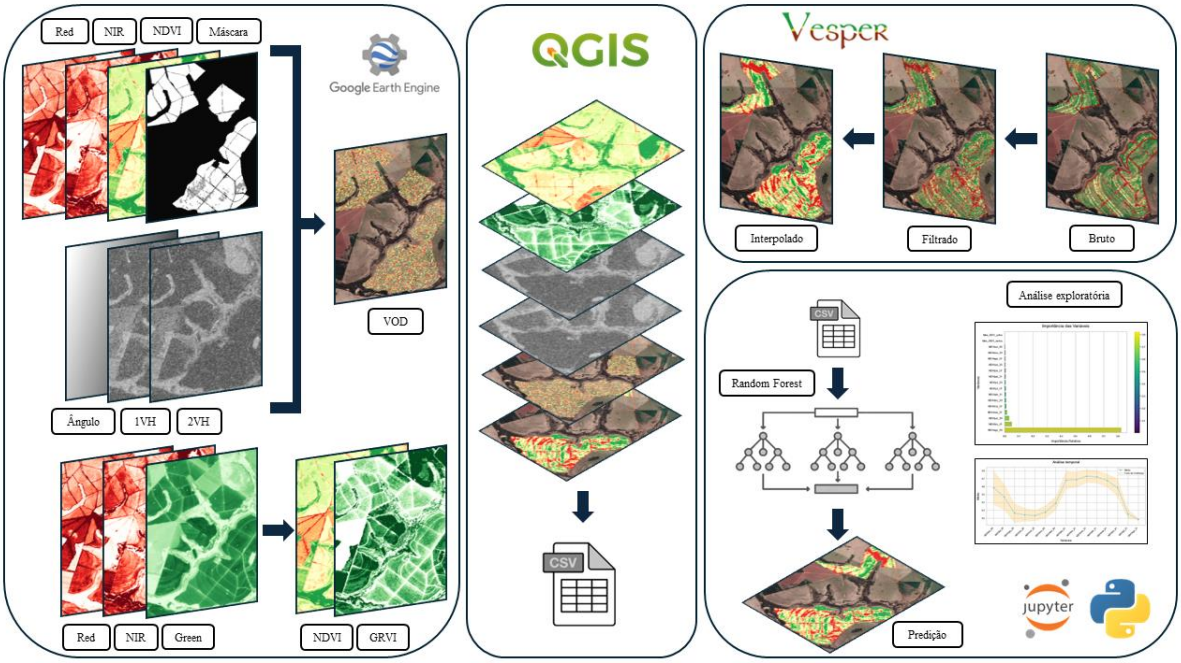


FIGURA 1. Fluxograma da metodologia do presente trabalho.

O modelo preditivo de produtividade foi desenvolvido por meio da técnica de *Random Forest* (RF), algoritmo supervisionado de *Machine Learning* (ML), no qual uma variável dependente é explicada em termos de N variáveis independentes medidas em qualquer escala (SANCHES et al., 2019). Neste estudo, foram utilizados 30% dos dados para teste, sendo a variável dependente a produtividade e as variáveis independentes os índices VOD (3), GRVI (4) e NDVI (5); bandas multiespectrais *Green* (G), *Red* (R) e *Near Infrared* (NIR), e banda C-SAR (polarização VH); mês de colheita.

GRVI = (*Green* - *Red*) / (*Green* + *Red*) (4)

NDVI = (*Near Infrared* - *Red*) / (*Near Infrared* + *Red*) (5)

Em que, *Green*: reflectância do verde (comprimento de onda central de 560 nm); *Red*: reflectância do vermelho (comprimento de onda central de 665 nm); *Near Infrared*: reflectância do infravermelho próximo (comprimento de onda central de 842 nm). A capacidade de predição do modelo foi avaliada na escala de pixel (resolução espacial de 10 m) a partir do coeficiente de determinação (R^2) entre a produtividade predita e a obtida pelos monitores de produtividade, a raiz do erro quadrático médio (RMSE) e o *Index of Agreement Modified* (dmod) que indica o grau de correspondência entre os valores preditos e os reais (PEREIRA et al., 2018).

RESULTADOS E DISCUSSÃO

Utilizando-se apenas dados do NDVI e GRVI de forma separada ao treinamento dos modelos preditivos, foi possível obter resultados promissores de predição de produtividade, com valores de R^2 iguais a 0,95, RMSE iguais a 7,12 e 7,61 Mg ha^{-1}, respectivamente, e dmod iguais a 0,99. Nesse sentido, as bandas multiespectrais utilizadas para calcular estes índices de vegetação também obtiveram resultados promissores, tais como R^2 = 0,96, RMSE = 6,55 Mg ha^{-1}, dmod = 0,99. Em

relação aos dados SAR e ao índice VOD, os resultados foram inferiores àqueles obtidos por sensores multiespectrais, R^2 iguais a 0,85 e -2,90, RMSE iguais a 12,63 e 3,82 Mg ha^{-1}, dmod iguais a 0,96 e 0,62, respectivamente (Tabela 1). Apesar disso, a banda C-SAR pode ser uma alternativa viável aos dados multiespectrais quando não há imagens com ausência de nuvens na região ou época de interesse. Resultados semelhantes foram obtidos por Canata et al. (2021), também utilizando dados de colheita de cana-de-açúcar e imagens multiespectrais em algoritmo RF, com R^2 = 0,70, RMSE = 4,63 Mg ha^{-1} para bandas espectrais *Red*, *Near Infrared*, *Red Edge*, *Blue* e *Green*.

TABELA 1. Parâmetros estatísticos obtidos na modelagem de predição de produtividade por *Random forest*.

		R^2	RMSE	dmod
NDVI	Treinamento	0,99	2,82	0,99
	Teste	0,95	7,12	0,99
GRVI	Treinamento	0,99	2,97	0,99
	Teste	0,95	7,61	0,99
Multiespectral	Treinamento	0,99	2,58	0,99
	Teste	0,96	6,55	0,99
VH	Treinamento	0,98	4,79	0,99
	Teste	0,85	12,63	0,96
VOD	Treinamento	0,86	7,08	0,95
	Teste	-2,90	3,82	0,62

(*) RF = *Random Forest*; NDVI = Normalized Difference Vegetation *Index*; GRVI = *Green-Red Vegetation Index*; Multiespectral = bandas *Red*, *Green* e *Near Infrared*; VH = imagens com polarização VH da banda C do sensor SAR; VOD = *Vegetation Optical Depth*.

Analisando-se a importância de cada variável no modelo preditivo de RF é possível notar que, em cada conjunto de dados, diferentes meses foram mais importantes que os demais (Figura 2). No conjunto de dados de NDVI, bandas multiespectrais e banda C-SAR, o mês de agosto de 2020 foi o de maior relevância relativa, enquanto para o índice GRVI foi o mês de junho de 2020. Isto revela que a fase de rebrota da cana-de-açúcar é um momento crucial para a estimativa de produtividade, visto que as datas de colheita foram junho e julho de 2021. Já a importância das variáveis no RF utilizando o conjunto de VOD mostrou-se o inverso, visto que o mês de maior contribuição foi julho de 2021.

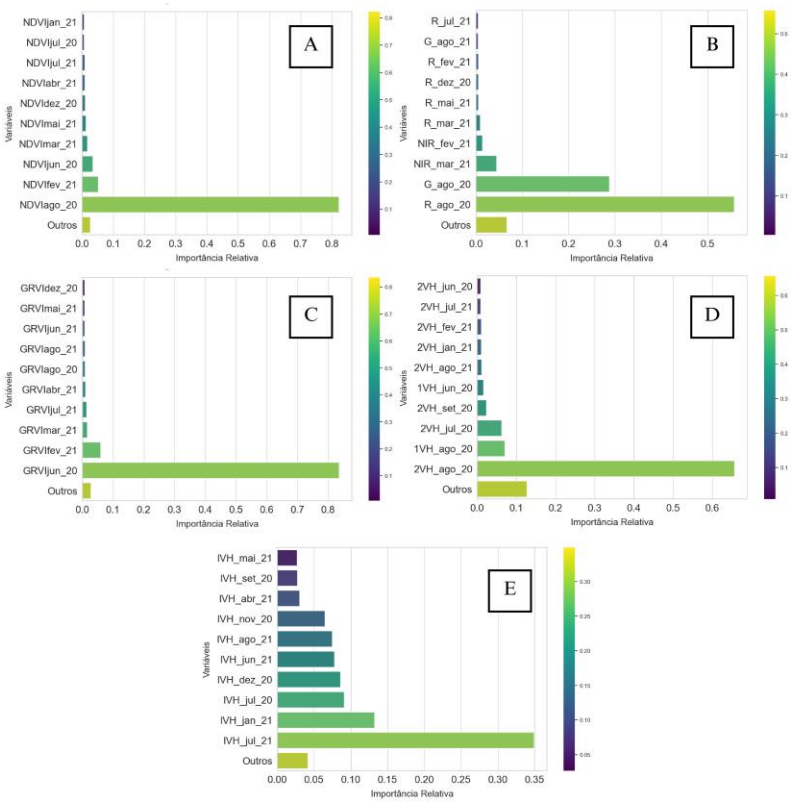


FIGURA 2. Importância relativa entre variáveis para modelos de predição de produtividade. (A) NDVI = *Normalized Difference Vegetation Index*; (B) R = *Red*, NIR = *Near Infrared*, G = *Green*; (C) GRVI = *Green-Red Vegetation*; (D) 1VH e 2VH = Imagens t1 e t2 com polarização VH obtidas da banda C do sensor SAR; (E) IVH = *Vegetation Optical Depth* (VOD).

A partir da Figura 2 é possível notar que as bandas do espectro eletromagnético que tiveram maior relevância foram a *Red* e *Green*. Este fato pode estar intimamente ligado à alta atividade fotossintética durante o período de rebrota da cana-de-açúcar, uma vez que quanto maior absorção do *Red* e menor absorção do *Green* pelas clorofilas, maior é a taxa fotossintética (FORMAGGIO & SANCHES, 2017).

Analisando-se as matrizes de correlação entre as variáveis mais importantes relativamente em seus respectivos bancos de dados e parâmetros biofísicos da cana-de-açúcar, como o corte e a produtividade, foi possível verificar correlações positivas ao NDVI, VOD e banda C-SAR (Figura 3). Já o índice GRVI e banda *Red*, obtiveram correlações negativas aos dados de corte e produtividades reais e preditas. Globalmente, todas as variáveis independentes obtiveram valores significativos de correlação com as produtividades reais e preditas, com exceção do índice VOD que permaneceu com resultados inferiores.

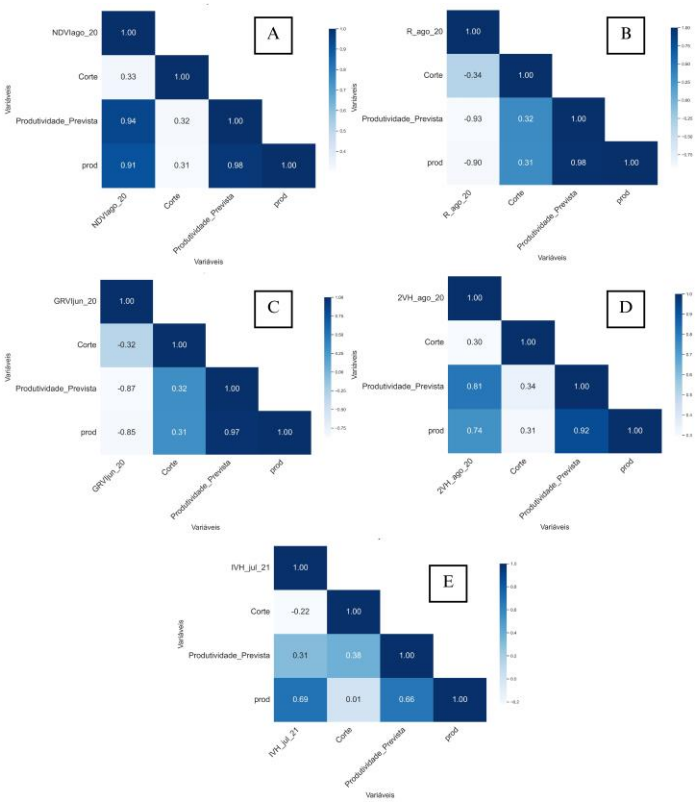


FIGURA 3. Matrizes de correlação entre variáveis dependentes e independentes. (A) NDVI = *Normalized Difference Vegetation Index*, prod = produtividade real; (B) R = *Red*; (C) GRVI = *Green-Red Vegetation*; (D) 2VH = Imagem t2 com polarização VH obtida da banda C do sensor SAR; (E) IVH = *Vegetation Optical Depth* (VOD).

É possível observar, em uma análise temporal do comportamento espectral da cana-de-açúcar (Figura 4), que os índices NDVI e GRVI apresentaram uma tendência semelhante ao longo dos meses (Figura 4A, B). Com relação aos dados multiespectrais das bandas *Green*, *Red* e *Near Infrared* (Figura 4C), constatou-se o comportamento inverso aos índices NDVI e GRVI, visto que nos meses com maiores valores dos índices, a banda R teve alta absorção e as bandas NIR e G tiveram baixa absorção. O reflexo deste comportamento espectral é esperado nestes índices de vegetação em razão de estarem relacionados à atividade fotossintética, sendo esta alta quanto maiores forem os valores dos índices NDVI e GRVI. Com isso, quanto maiores os valores de NDVI e GRVI, maior deve ser a absorbância do *Red*, e reflectância do *Green* e *Near Infrared* (FORMAGGIO & SANCHES, 2017).

O comportamento da polarização VH da banda C do sensor SAR (Figura 4D) foi mais consistente ao longo dos meses, não evidenciando períodos de mudança mais acentuada. No entanto, foi possível notar tendência de aumento no mesmo período que os índices multiespectrais, iniciando-se em outubro de 2020. Diferentemente do NDVI e GRVI, o SAR teve um decréscimo gradual até o período da colheita, o que pode indicar a correlação entre a banda C e a biomassa da cana-de-açúcar.

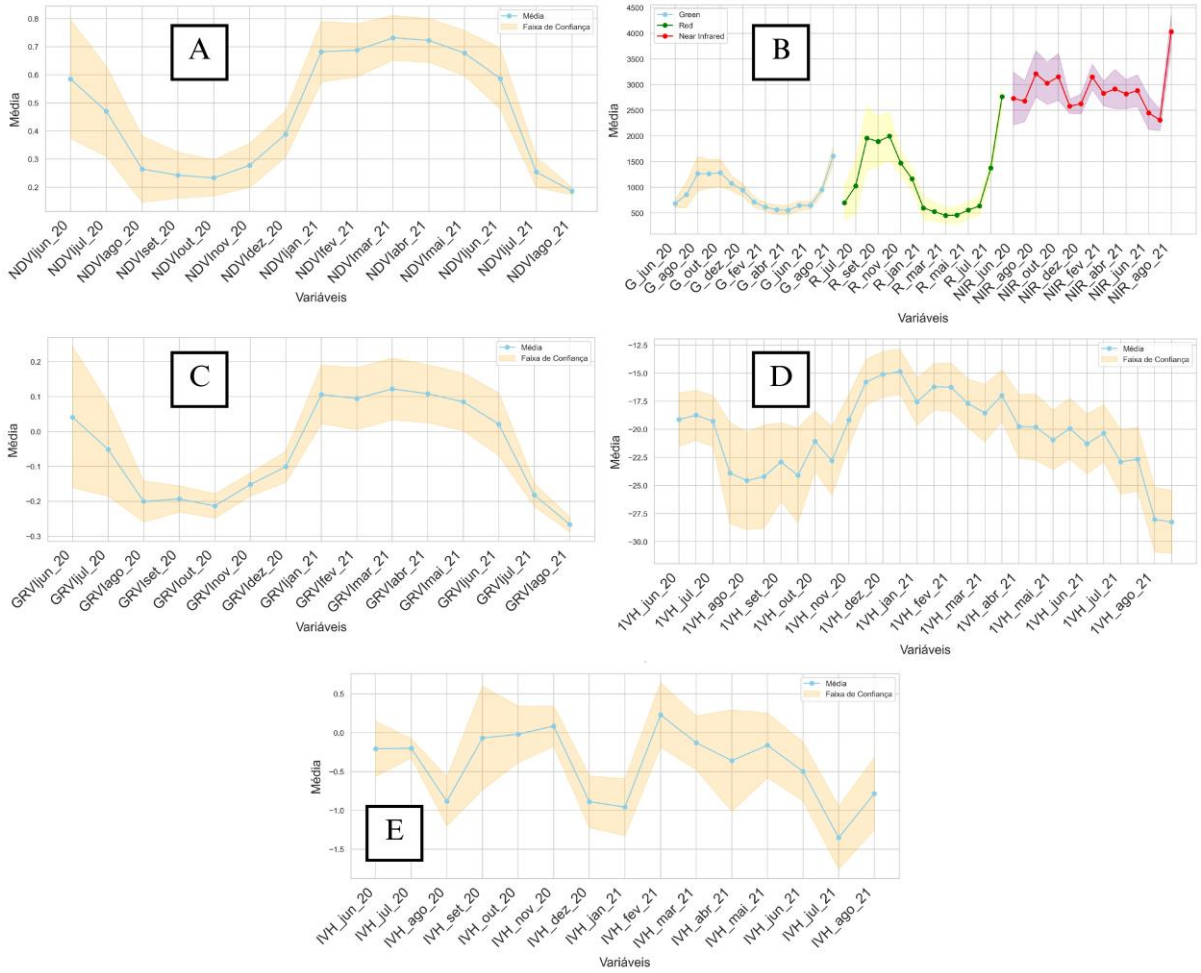


FIGURA 4**.** Análise temporal dos anos de 2020 e 2021 das variáveis independentes com médias mensais.

(A) NDVI = *Normalized Difference Vegetation Index*; (B) R = *Red*, NIR = *Near Infrared*, G = *Green*; (C) GRVI = *Green-Red Vegetation*; (D) 1VH e 2VH = Imagens t1 e t2 com polarização VH obtidas da banda C do sensor SAR; (E) IVH = *Vegetation Optical Depth* (VOD).

Outro aspecto importante verificado é que os meses de maior taxa fotossintética e maior biomassa não foram os mais significativos ao treinamento dos modelos preditivos por RF, na verdade ocorreu o inverso. Dessa forma, é possível constatar a importância dos primeiros meses de rebrota da cana-de-açúcar à estimativa de produtividade ao final da colheita. Com relação ao índice VOD (Figura 4E), não foi possível identificar uma tendência de comportamento. Sendo necessário mais estudos acerca do comportamento do VOD em diferentes localidades e épocas.

CONCLUSÃO

Os índices de vegetação NDVI e GRVI obtidos por imagens de sensor multiespectral embarcado no satélite Sentinel-2, bem como as bandas do espectro eletromagnético *Red* e *Green*, obtiveram resultados promissores na predição de produtividade na cana-de-açúcar por meio do algoritmo de aprendizagem de máquina *Random Forest*, com R^2 acima de 0,95 e RMSE abaixo de 6,55 Mg ha^{-1}.

No campo das micro-ondas, a polarização VH da banda C do sensor SAR foi a mais promissora em comparação ao índice VOD, com R^2 = 0,85 e RMSE = 12,63 Mg ha^{-1}. Sendo assim, pode ser utilizada de forma alternativa aos dados multiespectrais quando não houver imagens com ausência de nuvens na região ou época de interesse.

Portanto, foi possível obter modelos preditivos de produtividade em alta resolução espacial em canaviais antes da colheita, sendo as imagens de SAR e multiespectrais alternativas promissoras na ausência de dados de monitores de produtividade.

AGRADECIMENTOS

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pelo financiamento da presente pesquisa, processo nº 2023/12735-7. À Solinftec pelo suporte no desenvolvimento do projeto.

REFERÊNCIAS

CANATA, T. F.; MOLIN, J. P.; SOUSA, R. V. de. A measurement system based on LiDAR technology to characterize the canopy of sugarcane plants. **Engenharia Agrícola**, v.39, n.2, 2019.

CANATA, T. F.; WEI, M. C. F.; MALDANER, L. F.; MOLIN, J. P. Sugarcane Yield Mapping Using High-Resolution Imagery Data and Machine Learning Technique. **Remote Sensing**, v.13, n.2, 2021.

CHAPARRO, D.; PILES, M.; VALL-LLOSSERA, M.; CAMPS, A.; KONINGS A. G.; ENTEKHABI D. L-band vegetation optical depth seasonal metrics for crop yield assessment. **Remote Sensing of Environment**, v. 212, 2018.

CONAB (2023). Acompanhamento de safra brasileira: cana-de-açúcar. Primeiro levantamento, Brasília: Conab, 14.p.

EL HAJJ, M.; BAGHDADI, N.; WIGNERON, J. P.; ZRIBI, M.; ALBERGEL, C.; CALVET, J. C.; FAYAD, I. First Vegetation Optical Depth Mapping from Sentinel-1 C-band SAR Data over Crop Fields. **Remote Sensing**, v.11, n.23, 2019.

FORMAGGIO, A.R.; SANCHES, L.D. **Sensoriamento Remoto em Agricultura**. São Paulo: Oficina de Textos, 2017.

KONINGS, A. G.; RAO, K.; STEELE-DUNNE, S. C. Macro to micro: microwave remote sensing of plant water content for physiology and ecology. **New Phytologist**, v. 223, 2019.

KLUYVER, T.; RAGAN-KELLEY, B.; FERNANDO, E.; GRANGER, B.; BUSSONNIER, M.; FREDERIC, J.; WILLING, C. Jupyter Notebooks - a publishing format for reproducible computational workflows. **IOS Press**, 2016.

MALDANER, L. F.; CANATA, T. F.; MOLIN, J. P. An Approach to Sugarcane Yield Estimation Using Sensors in the Harvester and ZigBee Technology. **Sugar Tech 24**, v.24, 2022.

MALDANER, L. F.; MOLIN, J. P. Data processing within rows for sugarcane yield mapping. **Scientia Agricola**, v.77, n.5, 2020.

MALDANER, L. F.; MOLIN, J. P.; SPEKKEN, M. Methodology to filter out outliers in high spatial density data to improve maps reliability. **Scientia Agricola**, v.79, n.1, 2022.

MINASNY, B.; MCBRATNEY, A. B.; WHELAN, B. M. Vesper version 1.62. Sydney, Australian Centre for Precision Agriculture. **The University of Sydney**, 2005.

MOMIN, M. A.; GRIFT, T. E.; VALENTE, D. S.; HANSEN, A. C. Sugarcane yield mapping based on vehicle tracking. **Precision Agric 20**, v.20, 2019.

MOZAMBANI, C. I. **Determinantes da adoção de práticas e tecnologias de agricultura de precisão por fornecedores de cana-de-açúcar no estado de São Paulo**. Tese (Doutorado em Engenharia de Produção) - Universidade Federal de São Carlos, São Carlos, 2021.

PEREIRA, H. R.; MESCHIATTI, M. C.; PIRES, R. C. de M.; BLAIN, G. C. On the performance of three indices of agreement: an easy-to-use r-code for calculating the Willmott indices. **Bragantia**, v.77, n.2, 2018.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W.; HARLAN, J. C. **Monitoring the vernal advancement and retrogradation (greenwave effect) of natural vegetation**. Greenbelt: NASA, 1974.

SANCHES, G. M.; MAGALHÃES, P. S. G.; FRANCO, H. C. J. Site-specific assessment of spatial and temporal variability of sugarcane yield related to soil attributes. **Geoderma**, v.334, 2019.

SANTOS, E. P.; SANTOS, I. C.; MOREIRA, M. C.; AMARAL, C. H.; SILVA, D. D. Índices de Vegetação SAR (Synthetic Aperture Radar) e sua relação com a Biomassa Florestal. **XX Simpósio Brasileiro de Sensoriamento Remoto**, Florianópolis, v. 20, 2023.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v.8, n.2, 1979.

WU, J.; HE, J.; CHRISTAKOS, G. Chronotopologic krigology. **Elsevier eBooks**, p. 293-344, 2022b.

WU, J.; HE, J.; CHRISTAKOS, G. Classical geostatistics. **Elsevier eBooks**, p. 149-211, 2022a.

XIE, L.; WANG, J.; CHENG, S. Performance Evaluation of a Chopper System for Sugarcane Harvester. **Sugar Tech 21**, v.21, 2019.

ZHU, L.; LIU, X.; WANG, Z.; TIAN, L. High-precision sugarcane yield prediction by integrating 10-m Sentinel-1 VOD and Sentinel-2 GRVI indexes. **European Journal of Agronomy**, v.149, 2023.

DESENVOLVIMENTO DE PLATAFORMA ROBÓTICA COM NAVEGAÇÃO AUTÔNOMA

Jamil de Almeida Baltazar [1]; Andre Luiz de Freitas Coelho [2]; Domingos Sárvio Magalhães Valente [2]; Flora Maria de Melo Villar [2]

[1]Bolsista. Viçosa -MG. Depto. de Engenharia de Agrícola, Universidade Federal de Viçosa; [2]Professor. Viçosa -MG. Depto. de Engenharia de Agrícola, Universidade Federal de Viçosa

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Robôs agrícolas são veículos autônomos com grande potencial para mitigar os problemas como segurança alimentar, sustentabilidade dos sistemas agrícolas e demanda de mão de obra. Contudo, aspectos como custo de aquisição, precisão, segurança, confiabilidade e autonomia motivam o desenvolvimento de novos robôs agrícolas. Assim, objetivou-se desenvolver uma plataforma robótica, com navegação autônoma com orientação e navegação por meio de módulos de GNSS-RTK e sensor IMU. Desenvolveu-se, inicialmente, o sistema mecânico, elétrico e eletrônico da plataforma robótica. Um algoritmo de navegação com base na cinemática de veículo diferencial foi desenvolvido para que a plataforma robótica pudesse executar uma rota pré-definida de forma autônoma. Para analisar o desempenho da plataforma robótica, uma rota foi planejada de forma a simular o deslocamento em dez entrelinhas de cultura com espaçamento 2,5 m e comprimento 40 m. A plataforma robótica executou a rota oito vezes e uma *webcam* foi utilizada para obter imagem que permitiram medir o erro lateral. Obteve-se maior erro lateral de 0,233 m a 0,364 m, média do erro absoluto de 0,081 m a 0,109 m, desvio padrão de 0,019 m a 0,077 m e raiz do erro quadrático médio de 0,101 m a 0,132 m. Observou-se potencial para uso da plataforma robótica desenvolvida na agricultura, seja para atividades de monitoramento de solo e/ou planta ou para operações agrícolas.

PALAVRAS-CHAVE: algoritmo de navegação; monitoramento agrícola; robôs agrícolas

ABSTRACT

Agricultural robots are autonomous vehicles with great potential to mitigate issues such as food security, sustainability of agricultural systems, and labor demand. However, aspects such as acquisition cost, precision, safety, reliability, and autonomy drive the development of new agricultural robots. Thus, the objective was to develop a robotic platform with autonomous navigation using GNSS-RTK modules and IMU sensor-based guidance and navigation. Initially, the mechanical, electrical, and electronic systems of the robotic platform were developed. A navigation algorithm based on differential vehicle kinematics was developed so that the robotic platform could autonomously execute a predefined route. To analyze the performance of the robotic platform, a route was planned to simulate movement in ten crop rows with a spacing of 2.5 m and a length of 40 m. The robotic platform executed the route eight times, and a webcam was used to obtain images that allowed measurement of the lateral error. Lateral errors ranged from 0.233 m to 0.364 m, with an average absolute error of 0.081 m to 0.109 m, a standard deviation of 0.019 m to 0.077 m, and a root mean square error of 0.101 m to 0.132 m. The potential for using the developed robotic platform in agriculture was observed, whether for soil and/or plant monitoring activities or agricultural operations.

KEYWORDS: ;

INTRODUÇÃO

Nos últimos anos, o setor agrícola tem enfrentado desafios, como preocupações com a sustentabilidade dos sistemas produtivos, questões de segurança alimentar, escassez de insumos, mudanças climáticas e falta de mão- de-obra. Tais desafios tem motivado desenvolvimento de soluções inovadoras, ocasionando a modernização da agricultura. Nesse contexto, o uso de robôs agrícolas é um dos recentes avanços da agricultura, permitindo aumentar a qualidade e eficiência das operações, e consequentemente, mitigar os desafios apresentados (KARUNATHILAKE et al., 2023; LI, MING et al., 2009). Os robôs agrícolas podem ser utilizados para monitoramento de plantas e/ou solo e para execução de operações. Como exemplos de monitoramento de plantas e/ou solo tem-se detecção de estresse nutricional, estresse hídrico, ataque de pragas e doenças, infestação de plantas daninhas e predição de produtividade. Referente às operações agrícolas, robôs agrícolas podem ser utilizados desde preparo de solo até a colheita, passando pelo plantio, aplicação de defensivos e distribuição de fertilizantes (CISTERNAS et al.,2020; DONG, HEINEMANN, KASPER, 2021; SISHODIA; RAY; SINGH, 2020). No entanto, a adoção de robôs agrícolas não é isenta de desafios. De forma geral, os desafios encontrados na adoção de robôs agrícolas são similares aos desafios de adoção de outros veículos autônomos. Contudo, diferente de ambientes industriais, que são controlados e constantes, em robôs agrícolas alguns desafios são agravados visto às adversidades do ambiente agrícola. Um dos entraves para a difusão da adoção robôs agrícolas é o seu custo de aquisição, impedindo sua utilização por agricultores com menor capacidade de investimento. A precisão, a segurança, a confiabilidade e a autonomia são outros desafios e estão diretamente relacionadas às tecnologias de sensores e tipos de algoritmos utilizados no robô agrícola. A precisão na obtenção da posição e da orientação é de fundamental importância para que o robô possa executar a rota sem a ocorrência de desvios laterais que prejudiquem a atividade em execução (GENTILINI et al., 2021; RAHMADIAN; WIDYARTONO, 2020). Os desvios laterais aceitáveis variam em função da atividade que está sendo executada (PINI *et al*., 2020).

OBJETIVOS

Visto à necessidade de novas pesquisas para desenvolvimento tecnológico em robôs agrícolas, objetivou-se nesse trabalho desenvolver uma plataforma robótica com navegação autônoma com base em sistema de global de navegação por satélite com correção por cinemática em tempo real (GNSS-RTK) e sensor de unidade de medida inercial (IMU).

MATERIAL E MÉTODOS

O trabalho foi realizado no Laboratório de Mecanização Agrícola do Departamento de Engenharia Agrícola da Universidade Federal de Viçosa em três etapas. Na primeira etapa construiu-se sistema mecânico e montou-se o sistema elétrico e eletrônico da plataforma robótica. Na segunda desenvolveu-se um programa de computador para controlar a posição, orientação, direção e velocidade angular das rodas, fundamentais para a navegação autônoma. Na terceira avaliou-se o desempenho da navegação autônoma da plataforma.

Montagem mecânica e elétrico e eletrônica da plataforma robótica

O sistema mecânico da plataforma foi composto por chassi metálico de 1,2 m de largura, 0,7 m de comprimento e 0,6 m de vão livre, com tração fornecida por duas rodas dianteiras (Figura 1). Estas rodas foram acionadas por dois motores elétricos independentes. O sistema elétrico e eletrônico foi alimentado por duas baterias de 12 V, em série, formando um sistema de 24 V. Os dois motores das rodas foram controlados de forma independente, conectados a duas placas de desenvolvimento Arduino UNO R3. Cada motor foi equipado com um sensor *encoder* incremental de 400 mudanças de estado por revolução. As duas placas Arduino UNO R3 foram conectadas a um computador de placa única Nvidia Jetson Nano, rodando o sistema operacional Linux Ubuntu 18.04 LTS, que fazia o processamento central dos dados da plataforma robótica. Também foram conectados à Jetson Nano

um módulo GNSS-RTK EMLID modelo Reach configurado como *rover*, e um sensor IMU Adafruit modelo BNO055. Outro módulo GNSS-RTK EMLID modelo Reach foi configurado como *base*, com comunicação WiFi entre eles. A plataforma robótica foi configurada para utilizar dados do GNSS-RTK apenas nos modos *fix* e *float*, interrompendo o movimento na ausência desses sinais. No modo *fix*, os módulos GNSS-RTK possuem uma estimativa de erro inferior a 5 cm, enquanto no modo *float* é de 1 m.

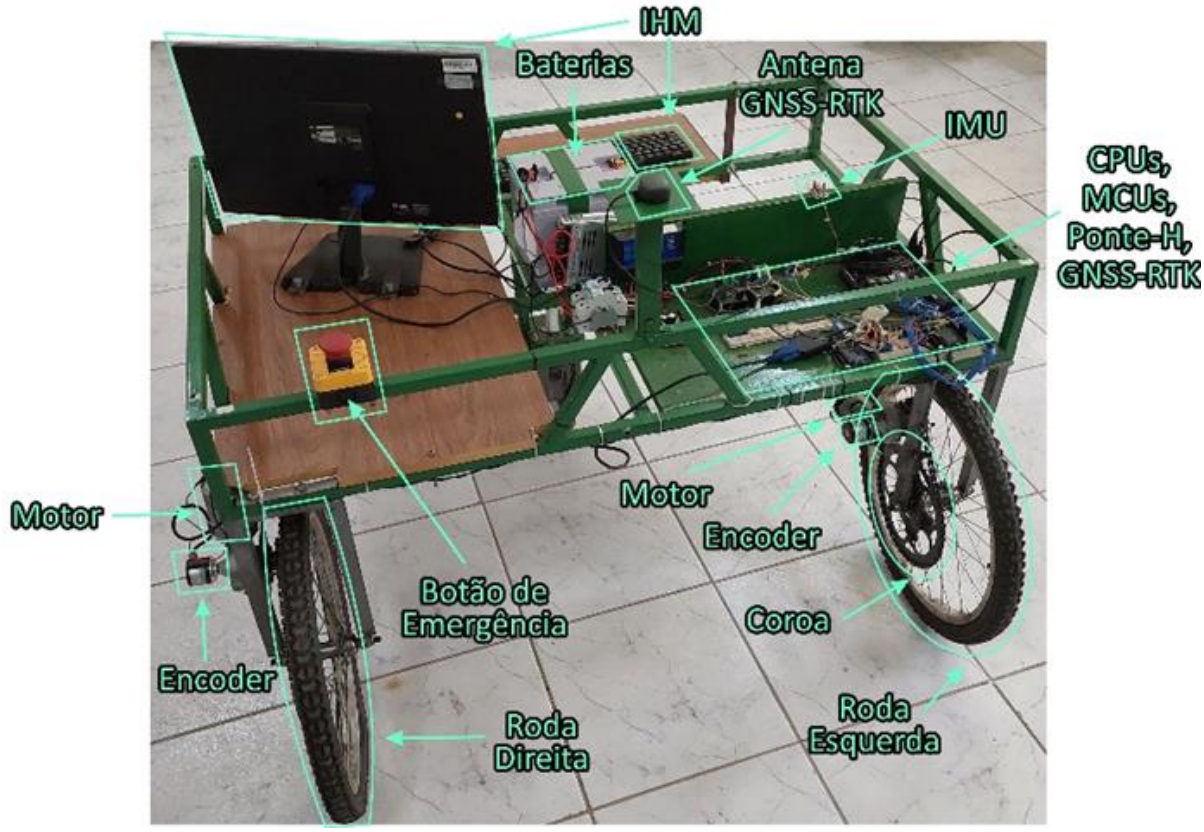


FIGURA 1. Plataforma robótica desenvolvida com destaque dos componentes mecânicos, elétricos e eletrônicos.

Programa de computador embarcado na plataforma robótica

O programa de computador foi desenvolvido com o *framework* ROS (*Robot operating system*), versão Melodic (Figura 2). O núcleo do ROS foi executado na Nvidia Jetson Nano, que se comunicou com duas placas Arduino UNO R3, com o módulo *rover* do GNSS-RTK e com o sensor IMU. O programa, baseado no ROS, foi organizado em nós, tópicos e serviços. Cada placa Arduino UNO R3, o módulo *rover* do GNSS-RTK, o sensor IMU e a Jetson Nano foram definidos como nós e as respectivas variáveis de interesse foram alocadas em tópicos.

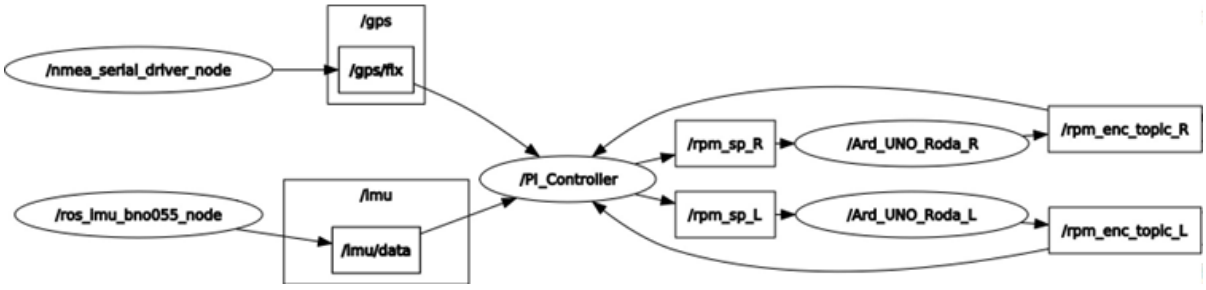


FIGURA 2. Organização dos nós e tópicos do programa embarcado na plataforma robótica utilizando o *framework Robot Operating System* (ROS). Elipses representam os nós, retângulos representam os

tópicos e setas representam o fluxo de informações: a informação pode sair de um nó (publicador) e ser publicada em um tópico, assim como a informação pode sair de um tópico e ser recebida por um nó (assinante).

O algoritmo de navegação foi desenvolvido com base na cinemática de um veículo do tipo diferencial. O movimento desse tipo de veículo é alcançado através do acionamento independente de suas duas rodas, oferecendo uma programação simplificada com um alto nível de controle sobre o robô. Para garantir o deslocamento preciso da plataforma robótica, foi implementado um controlador PID (Proporcional, Integral e Derivativo) no programa executado em cada uma das placas Arduino UNO R3. Este controlador ajusta as velocidades angulares das rodas de forma precisa e rápida, controlando a tensão média de alimentação dos motores elétricos através de PWM (Modulação por Largura de Pulso). Para o controle de direção da plataforma robótica, foi empregado um controlador PI (Proporcional e Integral), visando minimizar o erro do ângulo α (Figura 3). O controle de direção agiu sempre que houve mudança no ponto alvo ou qualquer perturbação na orientação da plataforma, buscando aproximar o ângulo α de zero e permitir que a plataforma robótica se deslocasse em linha reta em direção ao próximo ponto alvo. O ângulo θ foi fornecido pela IMU, inicialmente calibrada com zero voltado para leste. Associado ao controlador de direção, outro algoritmo foi desenvolvido para reduzir oscilações bruscas na resposta do controlador PI, especialmente em mudanças bruscas de direção. Neste algoritmo, se o ângulo α excedesse 10° ou fosse menor que -10°, a plataforma girava em torno de seu próprio eixo até que α se aproximasse de zero. Também foi desenvolvido um algoritmo para uma integração fraca entre GNSS e IMU, utilizando essa integração para realizar uma recalibração contínua da IMU com informações do módulo GNSS-RTK. O ponto de controle adotado pelo programa de computador foi o centro do entre rodas da plataforma robótica.

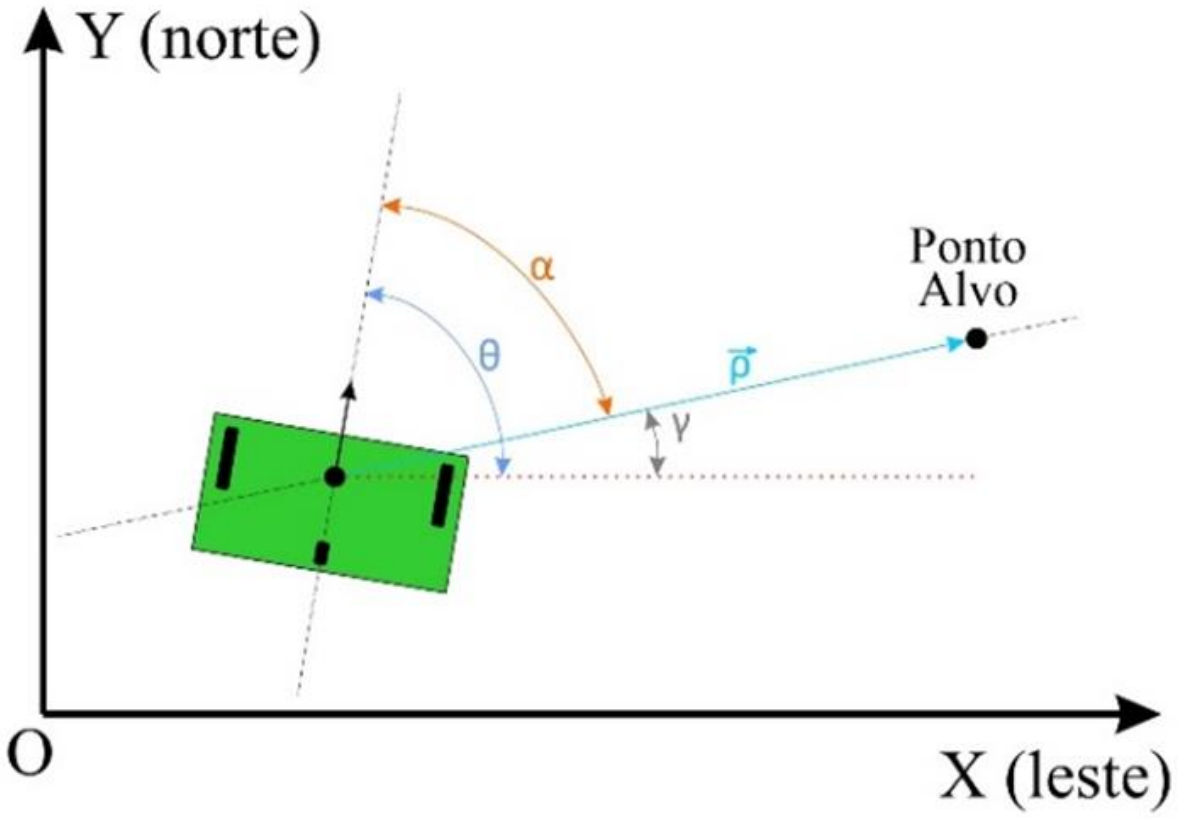


FIGURA 3. Parâmetros utilizados no controle de direção da plataforma robótica para alcance do ponto destino (ponto alvo).

A plataforma robótica foi desenvolvida para navegar e deslocar de forma autônoma em uma rota pré-definida. Essa rota foi definida por conjunto de pontos georreferenciados utilizando coordenadas

UTM (*Universal Transverse Mercator*) e *datum* WGS84. A orientação da plataforma foi considerada positiva ao longo do eixo x, correspondente ao ponto cardeal Leste. A posição absoluta (coordenadas x e y) foi determinada pelo módulo GNSS-RTK, enquanto a orientação absoluta (ângulo θ) foi fornecida pela IMU. A plataforma considerava ter alcançado o ponto alvo quando a distância até ele era menor que 0,5 m. Após passar por todos os pontos alvo na rota planejada, o programa foi configurado para fazer a plataforma retornar ao ponto de partida.

Avaliação de desempenho de navegação autônoma da plataforma robótica

O local de testes utilizado para avaliar a plataforma robótica foi uma área retangular plana de aproximadamente 1600 m², coberta por grama batatais (*Paspalum notatum*). Fitas de sinalização zebrada foram fixadas ao solo para simular linhas de uma lavoura de café, com espaçamento de 2,5 m entre as linhas e 40 m de comprimento cada. O mapeamento da área foi feito com 92 fotos aéreas capturadas por um drone a uma altitude de 20 m em relação ao solo. Para georreferenciar as fotos, foram coletados 5 pontos geográficos dentro da área de teste usando o módulo GNSS-RTK da plataforma robótica (Figura 4a). A rota a ser seguida pela plataforma robótica foi definida, a partir da foto ortomosaico e utilizando o programa QGIS 3.32.2, de forma que o centro do entre rodas da plataforma robótica passasse na região central entre duas fitas zebradas adjacentes. A rota planejada continha o deslocamento em 10 entrelinhas, além das manobras para troca de entrelinhas e o retorno para o ponto de partida (Figura 4b). Adotou a distribuição de pontos alvo a cada 3,0 m, totalizando 149 pontos alvo.

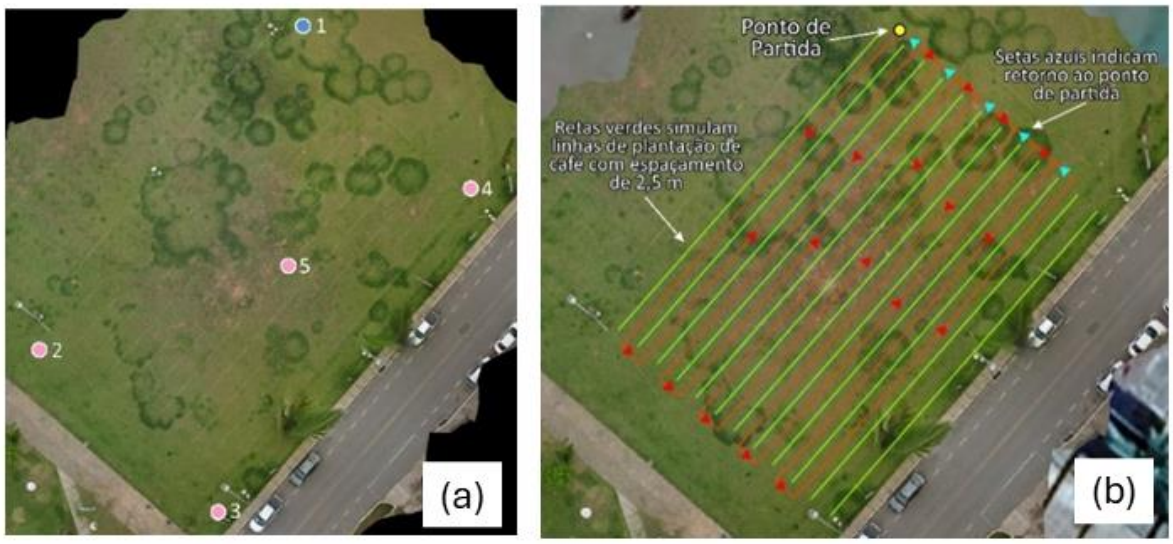


FIGURA 4. Área utilizada na avaliação de desempenho de navegação da plataforma robótica. (a) ortomosaico, (b) rota planejada

A rota planejada foi executada pela plataforma robótica oito vezes. Para analisar o desempenho mediu-se o desvio lateral da plataforma em relação à rota planejada. Para isso foram utilizadas imagens capturadas durante a execução da trajetória, obtidas por uma webcam Lenovo 300 FHD, com resolução de 1920 x 1080 pixels e ângulo de visão de 95º. A câmera foi acoplada à plataforma robótica de forma a capturar imagens ortogonais ao solo. Uma imagem foi coletada a cada 4,0 s (0,25 Hz). Um programa de computador em Python, utilizando a biblioteca OpenCV, foi desenvolvido para o processamento semiautomático das imagens a fim de se obter a distância ortogonal entre a roda direita da plataforma robótica e a fita zebrada (representando o centro da linha da cultura - Figura 5a). Para determinar a resolução espacial da imagem (número de pixels por centímetro), foram capturadas e processadas imagens contendo uma régua graduada, com resolução de 0,05 m, posicionada entre a roda e a fita zebrada (Figura 5b).

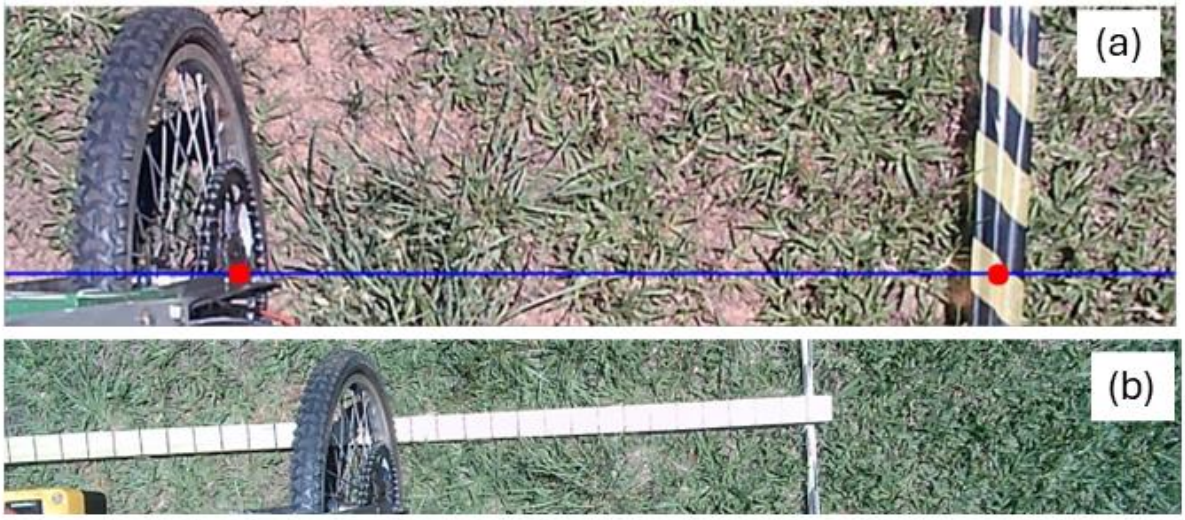


FIGURA 5. Avaliação do desvio lateral da plataforma robótica: (a) obtenção da distância entre a roda direita da plataforma e a fita zebrada, (b) escala graduada com resolução 0,05 m utilizada para obter a resolução espacial da imagem.

A partir da distância entre a roda da plataforma robótica e a fita zebra, e conhecendo-se a distância entre fitas zebradas (2,5 m) e a distância entre rodas da plataforma robótica (1,05 m), obteve-se a distância entre o centro entre rodas da plataforma e o centro entre duas fitas zebradas adjacentes. Essa distância representou o erro lateral da plataforma robótica, ou seja, o quanto o centro da plataforma robótica desviou lateralmente da rota planejada. Para cada execução da rota calculou-se métricas relacionadas ao erro lateral: maior erro lateral, erro absoluto médio, desvio padrão do erro lateral (DP) e erro quadrático médio (RMSE).

RESULTADOS E DISCUSSÃO

Nas oito execuções da rota planejada a plataforma robótica percorreu 4.259,1 m Na Tabela 1 é apresentada as métricas que permitiram mensurar o quanto a plataforma robótica desviou lateralmente da rota planejada.

TABELA 1. Métricas de erro lateral para análise do desempenho da navegação autônoma da plataforma robótica. MAE: erro absoluto médio, DP: desvio padrão, RMSE: erro quadrático médio

Repetição	Maior Erro Lateral (m)	MAE (m)	DP (m)	RMSE (m)
1	0,243	0,082	0,060	0,101
2	0,252	0,081	0,065	0,104
3	0,233	0,101	0,019	0,119
4	0,317	0,105	0,077	0,130
5	0,285	0,109	0,074	0,132
6	0,364	0,100	0,070	0,122
7	0,291	0,088	0,071	0,113
8	0,267	0,093	0,068	0,115

O maior erro lateral variou de 0,233 m a 0,364 m, enquanto o MAE e RMSE foram próximos de 0,10 m. Tais magnitudes de erros laterais, associados ao desvio padrão entre 0,019 e 0,077 m, indicaram que a plataforma robótica foi capaz de executar a rota planejada desviando-se lateralmente, em média, aproximadamente 0,1 m da rota. Para operações de monitoramento agrícola, utilizando por exemplo câmeras, e operações como pulverização e distribuição de fertilizantes, os erros laterais obtidos são aceitáveis (PINI *et al.*, 2020). Esses erros laterais podem ser associados à precisão dos dados de posição e orientação, obtido pelo GNSS-RTK e IMU, e aos desempenhos dos algoritmos utilizados. Assim, os erros laterais obtidos no presente trabalho podem ser reduzidos por meio do aperfeiçoamento dos algoritmos e uso simultâneo de outros sensores para obtenção da posição e orientação como câmeras, *Lidar* e *encoders* (ABDELHAFID *et al*., 2022; LEVOIR *et al*., 2020; YAN *et al*., 2022).

CONCLUSÃO

A plataforma robótica apresentou desempenho satisfatório na execução da rota planejada, com maior erro lateral variando de 0,233 m a 0,364 m, e MAE e RMSE próximos de 0,10 m. Visto os erros laterais obtidos, e da possibilidade de reduzi-los em trabalhos futuros, há potencial para uso da plataforma robótica desenvolvida na agricultura, seja para atividades de monitoramento de solo e/ou planta ou para operações agrícolas.

AGRADECIMENTOS

À Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) pelos recursos financeiros concedido ao projeto APQ-03052-17 intitulado "Sistema de baixo custo para orientação robótica em agricultura de precisão" , à Coordenação de Aperfeiçoamento do Pessoal de Nível Superior (CAPES) pela bolsa de estudos e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelos fomentos às pesquisas no Programa de Pós-Graduação em Engenharia Agrícola da Universidade Federal de Viçosa (PPGEA/UFV).

REFERÊNCIAS

ABDELHAFID, El Farnane et al. Localization based on DGPS for Autonomous Robots in Precision Agriculture. *In:* **2022 2nd International Conference on Innovative Research in Applied Science, Engineering and Technology (IRASET)**, Meknes, Morocco, 2022, pp. 1-4.

CISTERNAS, Isabel et al. Systematic literature review of implementations of precision agriculture. **Computers and Electronics in Agriculture**, v.176, p.1-11, 2020.

DONG, Fuhong; HEINEMANN, Wolfgang; KASPER, Roland. Development of a row guidance system for an autonomous robot for white asparagus harvesting. **Computers and Electronics in Agriculture**, v. 79, n. 2, p. 216-225,2021.

GENTILINI, Lorenzo et al. Trajectory Planning ROS Service for an Autonomous Agricultural Robot. *In:* **021 IEEE International Workshop on Metrology for Agriculture and Forestry (MetroAgriFor)**, Trento-Bolzano, Italy, 2021, pp. 384-389.

KARUNATHILAKE, E. M.B.M. et al. The Path to Smart Farming: Innovations and Opportunities in Precision Agriculture. **Agriculture**, v.13, n.8, p.1-26, 2023.

LEVOIR, Samuel J. et al. High-Accuracy Adaptive Low-Cost Location Sensing Subsystems for Autonomous Rover in Precision Agriculture**. IEEE Open Journal of Industry Applications,** v. 1, p. 74-94, 2020.

LI, Ming et al. Review of research on agricultural vehicle autonomous guidance. **International Journal of Agricultural and Biological Engineering** v. 2, n. 3, p. 1-16, 2009.

PINI, Marco et al. Experimental Testbed and Methodology for the Assessment of RTK GNSS Receivers Used in Precision Agriculture. **IEEE Access,** v. 8, p. 14690-14703, 2020.

RAHMADIAN, Reza; WIDYARTONO, Mahendra. Autonomous Robotic in Agriculture: A Review. *In:* **2020 Third International Conference on Vocational Education and Electrical Engineering (ICVEE**), Surabaya, Indonesia, 2020, pp. 1-6.

SISHODIA, Rajendra P.; RAY, Ram L.; SINGH, Sudhir K. Applications of remote sensing in precision agriculture: A review. **Remote Sensing**, v. 12, n. 19, p. 1-31, 2020.

YAN, Yaxuan et al. Real-Time Localization and Mapping Utilizing Multi-Sensor Fusion and Visual-IMU-Wheel Odometry for Agricultural Robots in Unstructured, Dynamic and GPS-Denied Greenhouse Environments. **Agronomy**, v. 12, n. 8, 2022.

DETECÇÃO SEMIAUTOMATIZADA DE PLANTAS DE MANGUEIRA CV. TOMMY ATRAVÉS DA DETERMINAÇÃO DO MODELO DIGITAL DE ALTURA

GABRIEL FERREIRA DE OLIVEIRA [1]; VICTOR FELIPE CARVALHO DEVESA [2]; ANAIDE CAROLANE DA SILVA SANTOS [3]; JULIANE RAFAELE ALVES BARROS [4]; MIGUEL JULIO MACHADO GUIMARAES [5]

[1]Graduando em Agronomia . BR-230, São Raimundo das Mangabeiras - MA, 65840-000. Instituto Federal de Educação, Ciência e Tecnologia do Maranhão; [2]Engº Agrônomo. BR-230, São Raimundo das Mangabeiras - MA, 65840-000. Instituto Federal de Educação, Ciência e Tecnologia do Maranhão; [3]Graduanda em Agronomia . BR-230, São Raimundo das Mangabeiras - MA, 65840-000. Instituto Federal de Educação, Ciência e Tecnologia do Maranhão; [4]Pós-Doutoranda, Engª Agrônoma. Zona Rural, sn, Petrolina, PE. Embrapa Semiárido/FACEPE; [5]Engº Agrônomo, Doutor em Engenharia Agrícola, Professor. BR-230, São Raimundo das Mangabeiras - MA, 65840-000. Instituto Federal de Educação, Ciência e Tecnologia do Maranhão

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Este trabalho tem por objetivo avaliar uma metodologia de detecção e contagem de plantas em pomares de mangueira cv. Tommy, utilizando imagens obtidas por aeronave remotamente pilotadas (ARP). O trabalho foi realizado no Instituto Federal de Educação Ciência e Tecnologia do Maranhão, Campus São Raimundo das Mangabeiras, utilizando uma imagem aérea de uma área de cultivo de manga cv. Tommy, localizada no município de Juazeiro-BA. A imagem aérea foi confeccionada através do processamento digital de imagens obtidas por uma ARP. O processamento digital das imagens foi realizado tendo como base de processamento a técnica *Structure from motion* para geração dos modelos digitais de elevação (MDE), modelo digital do terreno (MDT) e ortomosaico. Em posse dos modelos digitais (MDS e MDT), foi utilizado o software SAGA GIS® para aplicar a metodologia de contagem de indivíduos através da determinação do modelo digital de altura. Os resultados obtidos foram avaliados utilizando os índices de precisão, Revocação e F1-Score. A metodologia avaliada apresenta resultados satisfatórios na detecção de plantas em pomares de mangueira, com valores de precisão, revocação e F1-Score de até 0,97, 0,87 e 0,90, respectivamente. O formato da copa interfere na precisão da detecção das plantas, logo, recomenda-se que seja realizado o manejo de poda nos pomares antes do levantamento aerofotogramétrico.

PALAVRAS-CHAVE: Contagens de plantas; Fruticultura; Sensoriamento remoto

ABSTRACT

The aim of this work is to evaluate a methodology for detecting and counting plants in Tommy mango orchards, using images obtained by remotely piloted aircraft (RPA). The work was carried out at the Federal Institute of Education Science and Technology of Maranhão, São Raimundo das Mangabeiras Campus, using an aerial image of an area where Tommy mangoes are grown, located in the municipality of Juazeiro-BA. The aerial image was created by digitally processing images taken by an ARP. The images were digitally processed using the Structure from motion technique to generate digital elevation models (DEM), digital terrain models (DEM) and orthomosaics. Once the digital models (MDS and MDT) were available, the SAGA GIS® software was used to apply the methodology for counting individuals by determining the digital height model. The results obtained were evaluated using the precision, recall and F1-Score indices. The methodology evaluated shows satisfactory results in detecting plants in mango orchards, with precision, recall and F1-Score values of up to 0.97, 0.87 and 0.90, respectively. The shape of the canopy interferes with the accuracy of plant detection, so it is recommended that the orchards be pruned before the aerophotogrammetric survey is carried out.

KEYWORDS: ;

INTRODUÇÃO

Atualmente o Brasil se encontra em crescimento tecnológico, acentuadamente o Geoprocessamento e o Sensoriamento Remoto como opção para o monitoramento de vários aspectos das lavouras de forma precisa e eficiente. Em consonância a essa evolução, a utilização de aeronaves remotamente pilotadas (ARP), se destaca, por auxiliarem a precisão no sistema produtivo e alvos específicos. Segundo a Agência Nacional de Aviação Civil (ANAC, 2017), ARP são aeronaves que possua alto grau de automatismo e podem ser empregadas nos setores comercial, corporativa ou experimental.

Por meio do uso do ARP pode se adquirir dados georreferenciados das culturas e, depende do tipo de sensor acoplado, pode-se realizar diversas avaliações tendo como base as interações da radiação através do estudo das assinaturas espectrais das culturas (PÁDUA et al., 2020). A aplicação dessas técnicas vem ganhando espaço por conta da redução de gastos, tamanho e quantidade de equipamentos necessários e por último a grande necessidade de otimizar produção. O monitoramento da população de plantas em áreas agrícolas é crucial para a coleta de dados sobre a produtividade, auxiliando no planejamento e na tomada de decisão. (SÁ et al., 2021). Habitualmente, o processo de observação e contagem de plantas ocorre de forma manual por trabalhadores rurais, que apesar da eficácia quanto a identificação, torna-se bastante ineficiente pela alta demanda de tempo e oneração da mão de obra (ABIDIN et al., 2017). Neste sentido, a aplicação de técnicas de processamento de imagens obtidas por ARP em áreas de cultivos de plantas isoladas é uma alternativa viável para auxiliar a tomada de decisão no campo.

Com isto, O objetivo deste estudo foi avaliar uma metodologia aplicável na detecção e contagem de plantas em pomares de mangueira cv. Tommy, utilizando imagens obtidas por aeronave remotamente pilotadas.

OBJETIVOS

Com isto, O objetivo deste estudo foi avaliar uma metodologia aplicável na detecção e contagem de plantas em pomares de mangueira cv. Tommy, utilizando imagens obtidas por aeronave remotamente pilotadas.

MATERIAL E MÉTODOS

O estudo foi realizado no Núcleo de Agricultura de Precisão e Irrigação - NUAPI do Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, Campus São Raimundo das Mangabeiras. Foi utilizada uma imagem aérea de uma área de cultivo comercial de manga cv. Tommy, localizada no município de Juazeiro-BA. A área avaliada foi manejada com tratos culturas conforme recomendações comerciais para o cultivo. A coleta das imagens foi realizada na fase reprodutiva do ciclo anual da cultura, cerca de 30 dias antes da colheita. A imagem aérea foi confeccionada através do processamento digital de imagens obtidas por uma aeronave remotamente pilotada (ARP) modelo DJI Phantom 4 Standart. O voo foi realizado a 70 m de altura, a 7 m s^{-1} de velocidade, com sobreposição lateral e frontal de 80%, e a câmera diretamente apontada para o solo, com ângulo de 90º. As configurações de aquisição de imagens foram ajustadas de acordo com a iluminação do dia. As imagens foram obtidas no dia 10 de janeiro de 2023, no turno na manhã, com voo realizado às 11:00. As condições do tempo no momento da coleta foram dia ensolarado com nuvem espaçadas, sem previsão de chuva.

O processamento digital das imagens (PDI) foi realizado tendo como base de processamento a técnica SFM (do inglês - *Structure from motion*), que é uma técnica de processamento de imagem utilizada

para reconstruir estruturas tridimensionais a partir de imagens bidimensionais sequenciais coletadas em sensores em movimento (JIANG et al., 2020), resultando nos modelos digitais de superfície (MDS), terreno (MDT), e ortomosaico.

Em posse dos modelos digitais (MDS e MDT), foi utilizado o software SAGA GIS® para aplicar a metodologia proposta por Sá et al. (2021), de contagem de indivíduos. A metodologia consiste em confeccionar o modelo digital de altura (MDH) da área de estudo, e em seguida realizar a vetorização da imagem em uma camada de pontos. No entanto, antes da vetorização faz-se necessário o tratamento da imagem para redução de ruídos através da aplicação do filtro gaussiano, o qual é um processo em que a convolução é realizada na imagem visando a suavização da imagem, com uma máscara construída de forma condizente com a distribuição normal bidimensional. Após a vetorização do MDH, foi realizada uma limpeza semiautomatizada na camada vetorial de pontos, na qual foram excluídos todos os pontos que obtiveram altura inferior a 0,5 m. Após a limpeza, todos os pontos foram considerados, para poder calcular a precisão do método. Em seguida, foi realizada a identificação e a demarcação manual de cada árvore presente nas três áreas de avaliação. Para efeito de avaliação e repetibilidade, a imagem foi dividida em três áreas de avaliação.

Os resultados obtidos foram avaliados utilizando os índices de Precisão, Revocação e F1-Score, onde árvores detectadas, pontos incorretos e árvores não detectadas correspondem aos números de verdadeiros positivos (VP), falsos positivos (FP) e falsos negativos (FN), respectivamente.

RESULTADOS E DISCUSSÃO

Pode-se observar que o processamento realizado produziu modelos digitais com boa reconstrução tridimensional, haja vista que foi possível distinguir com precisão as copas das árvores nos modelos digitais confeccionados (Figura 1). Para se obter modelos com boa reconstrução tridimensional através da técnica SFM é recomendado que se tenha uma boa quantidade de imagens de um mesmo ponto observado. Desta forma, quando este for o objetivo do levantamento, o operador do RPA deve configurar os parâmetros de voo de forma a garantir quantidade de imagens suficientes.

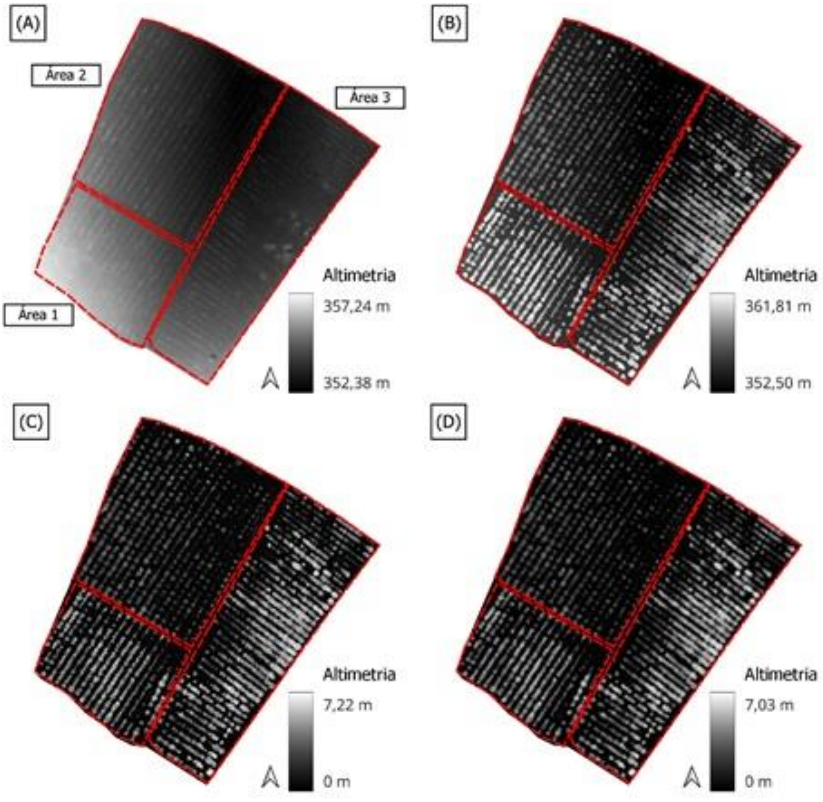


FIGURA 1. Produtos digitais obtidos a partir do processamento de imagens aéreas obtidas por aeronave remotamente pilotada em áreas de mangueira, cv. Tommy, localizados no município de Juazeiro, Vale do São Francisco. A - Modelo digital do terreno (MDT), B - de elevação (MDE), C - de altura (MDH) e D - de altura após filtro gaussiano (MDH-F).

Um dos principais parâmetros que irão interferir na quantidade de imagens obtidas é a sobreposição das imagens no momento da aquisição. Sá et al. (2021) e Oliveira (2020) relatam que para se obter bons resultados deve-se realizar voos com sobreposições acima de 80%, seja lateral ou longitudinal. Segundo Silva Júnior (2019) a sucessão de imagens deve ocorrer em intervalo de tempo de forma que entre a captura de duas fotografias haja uma superposição. Deste modo, alguns pontos da superfície são fotografados várias vezes evitando vazios durante a cobertura aerofotogramétrica, tornando possível extrair as suas medidas tridimensionais.

A Tabela 1 apresenta dos resultados dos índices de precisão, revocação e F1-Score nas três áreas avaliadas. Pode-se observar que a área 1 foi a área que apresentou a melhor precisão na aplicação da metodologia, seguida da área 3 e 2, respectivamente. Já para o índice de revocação, destacou-se a área 3. Estes resultados estão relacionados coma padronização da copa do pomar.

TABELA 1. Índices de precisão, revocação e F1-Score para avaliação da metodologia de detecção de plantas em pomares de mangueira, cv. Tommy, no Submédio do Vale São Francisco.

Área	Contagem real	Contagem SAGA	Precisão	Revocação	F1-Score
1	440	346	0,97	0,81	0,88
2	669	543	0,86	0,81	0,84
3	885	699	0,93	0,87	0,90

Os resultados obtidos neste estudo foram superiores aos obtidos por Sá et al. (2021), os quais utilizaram a mesma metodologia para avaliar pomares de mangueira na região do Submédio do Vale do São Francisco. Ao avaliar o F1-Score, pode-se observar valores elevados deste parâmetro. A utilização deste índice é importante pois o mesmo que associa tanto a precisão quanto a revocação, em um único índice. Os valores obtidos neste estudo foram superiores aos observados no trabalho desenvolvido por Sá et al. (2021), que registraram valores de F1-score: 0,301 ao utilizar a mesma metodologia na avaliação de pomares de mangueira cv. Tommy. Ao avaliar pomares das cultivares Kent e Palmer, os mesmos autores obtiveram resultados superiores, chegando a um índice F1-Score de 0,785. Tais autores não levantaram hipóteses sobre a diferença avaliada, haja vista que o objetivo do trabalho era a comparação de metodologias e não entre cultivares de mangueira, no entanto, esta diferença pode estar relacionada ao formato da copa e condução da poda dos pomares.

O índice de precisão é calculado com base na quantidade de pontos inseridos em plantas corretamente e na quantidade de pontos que foram inseridos, mas não possuem plantas naquele local. Desta forma, é possível inferir que, quanto maior o seu valor, menos serão o número de pontos inseridos em locais indevidos. Já o índice de revocação é calculado com base na quantidade de pontos inseridos em plantas corretamente e na quantidade de pontos que não foram inseridos em plantas existentes, ou seja, plantas não contadas pela metodologia. Sendo assim, infere-se que quanto maior o seu valor, menor a quantidade de plantas de deixaram de ser contadas pela metodologia.

O formato da copa irá interferir diretamente nos resultados obtidos pela técnica de detecção de plantas apresentada neste trabalho. Áreas com alta variação nos formatos das copas irão gerar modelos digitais de altura com grande variação na reconstrução tridimensional, o que interferirá na vetorização das alturas em pontos. Este comportamento foi observado na área 2, a qual apresentou irregularidade na copa das plantas (Figura 2), e consequentemente, menor precisão dos resultados obtidos (Tabela

1). Desta forma, recomenda-se que seja realizado o manejo de poda nos pomares antes do levantamento aerofotogramétrico.

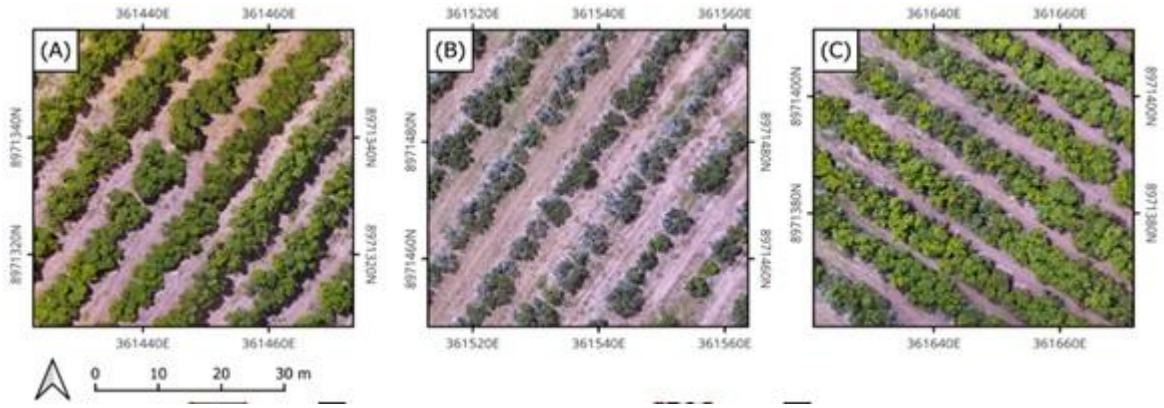


FIGURA 2. Detalhes das copas das árvores de áreas de mangueira, cv. Tommy, localizados no município de Juazeiro, Vale do São Francisco (A - Área 1; B - Área 2; C - Área 3).

CONCLUSÃO

A metodologia avaliada apresenta resultados satisfatórios na detecção de plantas em pomares de mangueira cv. Tommy. O formato da copa interfere na precisão da detecção de plantas de mangueira cv. Tommy, logo, recomenda-se que seja realizado o manejo de poda nos pomares antes do levantamento aerofotogramétrico, pois irá interferir diretamente nos dados.

Através dos resultados obtidos na aplicação da metodologia de detecção de indivíduos na contagem de plantas em pomares de mangueira cv. Tommy, conclui-se que o processamento de imagens de aeronaves remotamente pilotadas possibilita a geração de modelos digitais com boa reconstrução tridimensional.

Novo estudos devem ser realizados para validar o potencial de aplicação desta metodologia em variedades de mangueira diferentes.

AGRADECIMENTOS

Ao Instituto Federal de Educação, Ciência e Tecnologia do Maranhão, Campus São Raimundo das Mangabeiras, pelo apoio institucional.

REFERÊNCIAS

ABIDIN, H. SAMAD, M. N. PING, L. Y. AND NOOR, M. K. A. M. Evaluation of eCognition software for oil palm tree counting under different planting conditions and ages. **International Conference on Big Data Applications in Agriculture**, 2017.

ANAC, 2017. Regras sobre drones. Disponível em: http://www.anac.gov.br/noticias/2017/ regras-da-anac-para-uso-de-drones-entram-em-vigor/release_drone.pdf.

JIANG, S.; JIANG, C.; JIANG, W. Efficient structure from motion for large-scale UAV images: A review and a comparison of SfM tools. **ISPRS J Photogramm**, v. 167, p. 230-251, 2020.

OLIVEIRA, A. J. DE, SILVA, G. F. DA, SILVA, G. R. DA, SANTOS, A. A. C. DOS, CALDEIRA, D. S. A., VILARINHO, M. K. C., BARELLI, M. A. A., & OLIVEIRA, T. C. DE.

Potencialidades da utilização de drones na agricultura de precisão / Drones potentiality use in precision agriculture. **Brazilian Journal of Development**, v. 6, n. 9, p. 64140-64149, 2020.

PÁDUA, L. ADÃO, T. SOUSA, A. PERES, E. SOUSA, J. J. Individual grapevine analysis in a multi-temporal context using UAV-based multi-sensor imagery. **Remote Sensing**, v. 12, n. 1, p. 139, 2020

SÁ, C. A. de S.; DE MOURA, M. S. B.; GALVÍNCIO, J. D.; MIRANDA, R. de Q. DA SILVA, M. J. DOS SANTOS, C. V. B. . detecção semiautomática de árvores em pomar de mangueira irrigada a partir de imagens obtidas por drone. **IRRIGA**, v. 26, n. 3, p. 507-524, 2021.

SILVA JÚNIOR, E. E. de A. Geotecnologias e planejamento urbano: proposta metodológica e avaliação de dados obtidos por Aeronaves Remotamente Pilotadas (RPA) como contribuição à cartografia geotécnica. 2019. Tese (Doutorado) - **Programa de Pós-Graduação em Geotecnia, Universidade de Brasília**, 2019.

BANDAS MULTIESPECTRAIS SIMULADAS NA CARACTERIZAÇÃO E DISCRIMINAÇÃO DE TRATAMENTOS NUTRICIONAIS EM *Eucalyptus saligna*

Sally Deborah Pereira da Silva [3]; Lúcio de Paula Amaral [1]; Jocimar Caiafa Milagre [3]; Roberta Aparecida Fantinel [2]; Luciano Zucuni Pes [5]

[1]Docente. Av. Roraima 1000 - Prédio 44J Sala 213, Santa Maria-RS, CEP 97.105-900. Universidade Federal de Santa Maria (PPGAP;PPGEF); [2]Doutoranda. Av. Roraima 1000 - Prédio 44 Sala 5255, Santa Maria-RS, CEP 97.105-900. Universidade Federal de Santa Maria (PPGEF); [3]Doutorando. Av. Roraima 1000 - Prédio 44 Sala 5255, Santa Maria-RS, CEP 97.105-900. Universidade Federal de Santa Maria (PPGEF); [4]Egressa, Eng. Florestal. Av. Roraima 1000 - Prédio 70 Bloco F Sala 211-A, Santa Maria-RS, CEP 97.105-900. Colégio Politécnico da Universidade Federal de Santa Maria (PPGAP); [5]Docente. Av. Roraima 1000 - Prédio 70 Bloco F Sala 211-A, Santa Maria-RS, CEP 97.105-900. Colégio Politécnico da Universidade Federal de Santa Maria (PPGAP)

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Este estudo teve como objetivo investigar o uso de dados de espectrorradiometria na caracterização e discriminação de mudas clonais de *Eucalyptus saligna* submetidas a diferentes dosagens de fertilizantes. O estudo foi realizado em uma área experimental da Universidade Federal de Santa Maria e consistiu no plantio de 150 mudas de *E. saligna*. O delineamento experimental utilizado foi em blocos casualizados (DBC). Os tratamentos foram constituídos por 50 plantas que não receberam nenhuma adubação (T0); 50 plantas que receberam 20% das doses de adubação recomendada (N, P e K) (T1); e 50 plantas que receberam 50% das doses de adubação recomendada (N, P e K) (T2). Os espectros de refletância de superfície das folhas foram coletados usando o espectrorradiômetro FieldSpec®. Os dados foram submetidos a análise de variância e teste de Tukey ($p<0,05$). Os resultados demonstram que as bandas simuladas do sensor do *Red-edge* MX® (*Blue*, *Green* e *Red*, *Red-Edge*) foram eficientes em caracterizar e separar os tratamentos em dois grupos diferentes, demonstrando o potencial de uso da espectrorradiometria e do sensor do *Red-edge* MX® em análises futuras para monitorar deficiência de nutrientes em plantios florestais.

PALAVRAS-CHAVE: Floresta de precisão; espectrorradiometria; nutrição de plantas

ABSTRACT

This study aimed to investigate the usefulness of spectroradiometry data in the characterization and discrimination of *Eucalyptus saligna* clonal seedlings subjected to different fertilizer dosages. The study was carried out in an experimental area at the Federal University of Santa Maria and consisted of planting 150 E. saligna seedlings. The experimental design used was randomized blocks (DBC). The treatments consisted of 50 plants that did not receive any fertilization (T0); 50 plants that received 20% of the recommended fertilizer doses (N, P e K) (T1); and 50 plants that received 50% of the recommended fertilizer doses (N, P e K) (T2). Leaf surface reflectance spectra were collected using the FieldSpec® spectroradiometer. The data were subjected to analysis of variance and Tukey test ($p<0.05$). The results demonstrate that the simulated bands of the Red-edge MX® sensor (Blue, Green and Red, Red-Edge) were efficient in characterizing and separating the treatments into two different groups, demonstrating the potential use of spectroradiometry and the MX® sensor. Red-edge MX® in future analyzes to monitor nutrient deficiencies in forestry plantations.

KEYWORDS: Precision Forest; spectroradiometry; plant nutrition

INTRODUÇÃO

A produção de madeira proveniente de plantios florestais tem aumentado nas últimas décadas no Brasil devido principalmente à crescente demanda da indústria de celulose e papel. Segundo dados da Indústria Brasileira de Árvores (IBÁ), o país possui 9,93 milhões de hectares de plantios, dos quais 7,53 milhões de hectares (75,8%) são do gênero *Eucalyptus* (IBÁ, 2022). No Brasil, os plantios de eucalipto demonstram um potencial produtivo superior a outras regiões do mundo, com a média de produtividade aumentando de 10 m^3 ha^{-1} ano^{-1} em 1970 para 38,9 m^3 ha^{-1} ano^{-1} em 2021 (SILVA JUNIOR et al., 2021).

O aumento da produtividade dos plantios de eucalipto se deve a diversos fatores, tais como o progresso das técnicas de melhoramento genético, aprimoramento do manejo florestal, e a boa adaptação às condições edafoclimáticas brasileiras (PINHEIRO et al., 2019; SILVA JUNIOR et al., 2021). No entanto, os clones e híbridos de espécies melhoradas apresentam uma maior demanda nutricional e frequentemente sofrem com deficiências de macro e micronutrientes nos plantios (DAMASCENO et al., 2023). Nesse sentido, o monitoramento do estado nutricional nos plantios de *Eucalyptus* sp. ajuda a orientar o diagnóstico de deficiências e o manejo eficiente da nutrição das plantas.

Diante desse contexto, as técnicas de sensoriamento remoto têm demonstrado eficácia para subsidiar a aplicação de práticas de silvicultura/floresta de precisão, permitindo o monitoramento do estado nutricional das plantas de forma rápida, econômica e não destrutiva. As regiões espectrais do visível (480 - 680 nm, que compreende as bandas espectrais do azul, verde e vermelho) e do infravermelho próximo (700 - 1300 nm, que compreende as bandas espectrais da borda do vermelho e infravermelho próximo) foram definidas como indicadoras de deficiências nutricionais e de estresses em plantas (CARTER e KNAPPA, 2001; PONZONI et al., 2012; FORMAGGIO e SANCHES, 2017). Isso pode ser realizado por meio da coleta de dados de reflectância foliar utilizando sensores multiespectrais e hiperespectrais, embarcados em satélites, aeronaves remotamente pilotadas ou proximais (GRACIA-ROMERO et al., 2017; LI et al., 2018).

A análise dos comprimentos de onda em diversas bandas possibilita a obtenção de uma vasta gama de informações, o que permite uma análise mais detalhada das características espectrais das espécies de *Eucalyptus* sp. em resposta a diferentes dosagens de nutrientes aplicados. Dessa forma, o estresse da deficiência nutricional pode ser identificado através da assinatura espectral em um intervalo de tempo mais breve, agilizando a sua detecção em plantios florestais.

OBJETIVOS

Assim, este estudo teve por objetivo investigar o uso de dados de espectrorradiometria na caracterização e discriminação de mudas de *Eucalyptus saligna* Sm. submetidas a diferentes dosagens de fertilizantes, e estabelecer relação quanto a estresse oriundos de causas nutricionais.

MATERIAL E MÉTODOS

Área de estudo: O estudo foi realizado em uma área experimental localizada no campus-sede da Universidade Federal de Santa Maria (UFSM) denominada de Área Nova do Colégio Politécnico, no município de Santa Maria, Rio Grande do Sul, Brasil (Figura 1). De acordo com a classificação Köppen, a região possui clima do tipo Cfa (subtropical úmido com verão quente), onde os meses mais quentes variam de dezembro a fevereiro, com uma temperatura média de 22 ºC, enquanto os meses de junho, julho e agosto são os mais frios, com temperatura que varia de -3 °C a 18 °C (ALVARES et al., 2013). O solo predominante na área é classificado como Argissolo Vermelho Distrófico típico, que se caracteriza por apresentar teores mais altos de óxidos de ferro e baixa fertilidade natural. Além disso, o teor de argila no horizonte subsuperficial é bem maior do que no horizonte superficial (EMBRAPA, 2018).

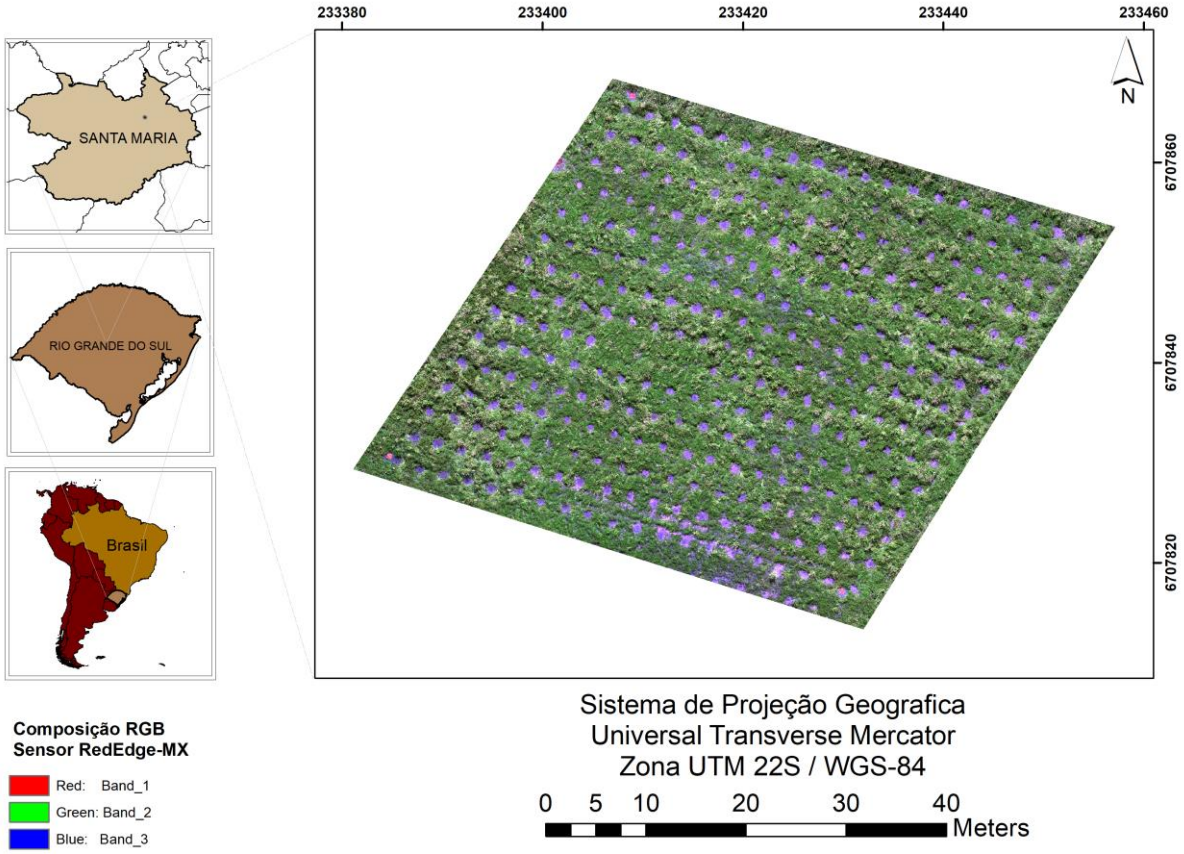


FIGURA 1. Plantio de *Eucalyptus* sp. localizado na Área Nova do Colégio Politécnico da Universidade Federal de Santa Maria, Santa Maria - RS, Brasil. Planting of *Eucalyptu*s sp. located in the Area Nova of the Polytechnic College of the Federal University of Santa Maria, Santa Maria - RS, southern Brazil.

Implantação do experimento: A área experimental é um talhão agrícola, que estava entre rotação de culturas (soja para milho) e foi utilizado semeadura de um mix plantas de cobertura, em composição com algumas espécies como *Avena sativa* L. (aveia), *Vicia cracca* L. (ervilhaca), *Raphanus sativus* L. (nabo forrageiro) para proteção do solo durante o inverno, no período de entressafras de soja (2022/2023) e milho (2023/2024).

O experimento foi instalado no dia 1º de julho de 2023, com plantio de 150 mudas clonais de *E. saligna*, com 120 dias de idade (ciclo de produção no viveiro), sendo um clone comercial utilizado pela empresa florestal CMPC (a maior empresa florestal em operação no estado do RS). O plantio das mudas foi realizado manualmente, sendo feitos o coroamento, abertura das covas e adubação. O espaçamento utilizado foi de 3,0 m x 2,5 m, abrangendo uma área de 50,0 m x 45,0 m (0,225 hectares), subdividida em blocos (Figura 2). O delineamento experimental utilizado foi em blocos casualizados (DBC).

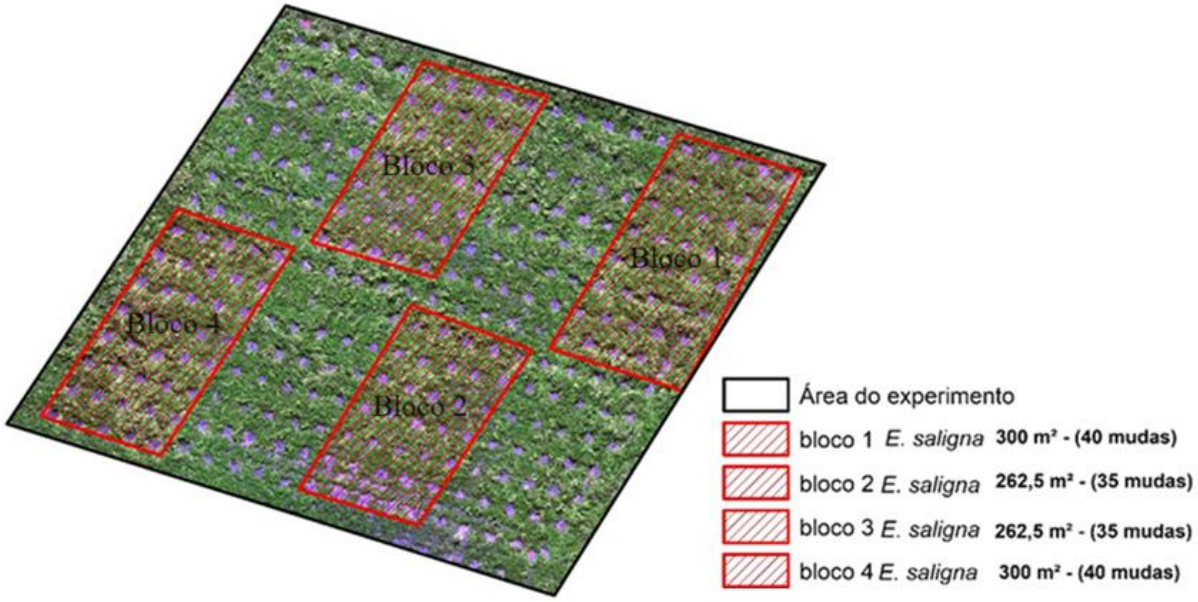


FIGURA 2. Delineamento experimental em blocos ao acaso, com quatro blocos utilizados para o plantio de *E. saligna* na Área Nova do Colégio Politécnico da Universidade Federal de Santa Maria, Santa Maria - RS, Brasil, 2023. Experimental design in randomized blocks, with four blocks used for planting *E. saligna* in the Area Nova of the Polytechnic College of the Federal University of Santa Maria, Santa Maria - RS, southern Brazil, 2023.

A aplicação dos tratamentos nutricionais foi feita com base no manual de calagem e adubação para os estados do Rio Grande do Sul e Santa Catarina (CQFS-RS/SC, 2016), que consideram como os regimes de fertilização todo o ciclo de crescimento da planta até a colheita, que pode variar entre 5 e 7 anos. Como o experimento realizado nesse estudo teve a duração de 120 dias, sendo avaliado o arranque inicial de crescimento do *E. saligna*, os tratamentos aplicados receberam 20% e 50% das doses de adubação de N, P, e K recomendadas pelo CQFS-RS/SC (2016). Dessa forma, os tratamentos foram constituídos da seguinte forma: 50 plantas não receberam nenhuma adubação (Testemunha - T0); 50 plantas receberam 20% das doses de adubação recomendada (Tratamento 1 - T1); e 50 plantas receberam 50% das doses de adubação recomendada (Tratamento 2 - T2). A fertilização foi realizada concomitante ao plantio, de modo manual, e as doses de adubação de referência foram de 30 kg ha^{-1} de N, 70 kg ha^{-1} de P_2O_5 e 70 kg ha^{-1} de K_2O. Foram utilizadas as fontes de fertilizantes convencionais: ureia ($CO(NH_2)_2$ - 45% de N); fosfato diamônico (DAP - 45% de P_2O_5); cloreto de potássio (KCl - 58% de K_2O). Após 45 dias do plantio, foi realizada uma adubação de cobertura nitrogenada (Tabela 1). Dentro de cada bloco, a distribuição de cada um dos tratamentos ocorreu muda a muda, sendo a mesma registrada em um croqui de controle, que possibilitava conhecer o tratamento aplicada em cada muda nos blocos, utilizado também para sistematizar as coletas de folhas para as análises espectrais.

Tabela 1 - Descrição dos tratamentos de fertilização de plantio e cobertura aplicados no plantio de E. saligna na Área Nova do Colégio Politécnico da UFSM, Santa Maria - RS. Description of the planting and covering fertilization treatments applied to the planting of E. saligna in the Area Nova of the Colégio Politécnico da UFSM, Santa Maria - RS.

Tratamentos	**Época**	**Modo**	**Dose (N) - ureia**	**Dose (P_2O_5) - DAP**	**Dose (K_2O) - KCl**
			g. planta $^{-1}$ (%)		
T0	Plantio	Cova	-	-	-

T1	Plantio	Cova	2 (20%)	23 (20%)	18 (20%)
	45 dias pós plantio	Cobertura	5 (20%)	-	-
T2	Plantio	Cova	4 (50%)	58 (50%)	45 (50%)
	45 dias pós plantio	Cobertura	12,50 (50%)	-	-

Amostragem foliar e leitura com espectroradiômetro: A coleta das folhas de *E. saligna* para as análises espectrorradiométricas ocorreu no mês de outubro de 2023, quando as mudas tinham 90 dias pós plantio. A coleta ocorreu em um único dia, entre às 9:00 e às 11:00 horas da manhã. Foram selecionadas folhas de plantas sadias, completamente expandidas e maturas fisiologicamente. Foram selecionadas cinco folhas das plantas de cada tratamento nutricional nos quatro blocos da área experimental, totalizando 20 folhas de cada tratamento. Após a coleta do material, as folhas foram embaladas em sacos de papel devidamente identificados e postas em caixa térmica hermeticamente fechada, com bolsas térmicas com gelo ao fundo da caixa para preservação do tecido vegetal. As amostras foram levadas para o Laboratório de Sensoriamento Remoto - CCR - UFSM (LABESERE/UFSM), onde as leituras de espectrorradiometria foram realizadas.

Os dados de reflectância espectral das folhas foram obtidos com o espectrorradiômetro FieldSpec®3, modelo FS3 350-2500 (Analytical Spectral Devices, Inc., EUA), sensível a uma faixa espectral de 350 nm a 2.500 nm, realizando leituras a cada nanômetro dentro desta faixa espectral. A calibração do espectroradiômetro antes da medição do valor da reflectância de cada tratamento foi realizada utilizando uma placa de referência padrão. As leituras tiveram início uma hora após o material vegetativo ter sido coletado. Para cada tratamento nutricional, foram realizadas 15 leituras (três leituras em cada folha), totalizando 180 leituras. Os dados de reflectância foram pré-processados para remover ruídos e garantir estabilidade no comportamento espectral (curvas de reflectância). Os dados no infravermelho de ondas curtas (SWIR) foram eliminados devido à baixa relação sinal-ruído.

Procedimentos estatísticos: Para a análise estatística, levou-se em consideração a reflectância espectral simulada das bandas de operação do sensor Micasense RedEdge-MX (MicaSense Inc., Seattle, WA, EUA) compreendidos entre 455 e 680 nm (faixa visível - azul, verde e vermelho) e o intervalo entre 710 e 880 nm (borda do vermelho e infravermelho próximo). A principal motivação foi a possibilidade de utilizar futuramente este sensor embarcado em aeronave remotamente pilotada, para gerar imagens multiespectrais, a serem utilizadas na diferenciação de plantas com estresse causado por deficiência nutricional em trabalhos futuros. A descrição das bandas espectrais utilizadas pelo sensor Micasense RedEdge-MX estão apresentadas na Tabela 2.

Tabela 2 - Bandas espectrais simuladas Blue, Green, Red, RedEdge e NIR e seus respectivos comprimentos de onda. Blue, Green, Red, RedEdge and NIR simulated spectral bands and their respective wavelengths.

Bandas espectrais Micasense RedEdge-MX	Intervalo de comprimento de onda (nm)	Largura de banda (nm)
Blue (azul)	455 - 495	20
Green (verde)	540 - 580	20
Red (vermelho)	658 - 678	10
Red-Edge (borda do vermelho)	707 - 727	10

NIR (infravermelho próximo)	800 - 880	40

Fonte: MicaSense® (2015)

Após a organização dos dados, os mesmos foram submetidos ao teste de normalidade de erros de Shapiro-Wilk e homogeneidade das variâncias de Oneillmathews (O'NEILL e MATHEWS, 2002), ambos ao nível de significância de 5% ($p > 0,05$). Na sequência, foi realizada a análise de variância (ANOVA) seguida pelo teste de Tukey para comparação de médias para testar as diferenças estatísticas entre os tratamentos nutricionais, com 95% de confiança ($p<0,05$). O teste de Tukey foi usado porque era importante identificar as regiões do espectro eletromagnético em que os tratamentos diferem significativamente uns dos outros. As análises estatísticas foram desenvolvidas no software Rstudio versão 3.5.0 (R CORE TEAM, 2021), com a aplicação do pacote estatístico ExpDes (FERREIRA et al., 2014).

Complementarmente foi realizada análise multivariada de componentes principais - ACP. Para realizar esta análise as reflectâncias obtidas em cada banda espectral de referência e em cada tratamento nutricional são consideradas variáveis e as repetições em cada tratamento e banda são considerados casos ou objetos. Previamente a análise, os dados são padronizados, onde para cada variável, são obtidas as diferenças de cada observa em relação a respectiva média, divididas pelos respectivos desvios padrões (Vicini et al., 2018). Para a ACP foi utilizado o programa Statistica 12.

RESULTADOS E DISCUSSÃO

Ao processar os dados de reflectância das folhas de *E. saligna* obtidos com o espectrorradiometro, foram obtidas as curvas espectrais médias para os três tratamentos de aplicações dos macronutrientes N, P e K (Figura 3), as quais foram enquadradas nos limites das bandas espectrais do sensor MicaSense RedEdge-MX®, para obter o valor médio da reflectância em relação a estas bands de referência. Através das assinaturas espectrais visuais, notou-se que as curvas de reflectância apresentaram padrão similar à curva espectral típica da vegetação ou de uma folha verde sadia, na qual a maior parte da luz visível é absorvida, enquanto quase metade da energia do infravermelho próximo é refletida (PONZONI et al., 2012, FORMAGGIO e SANCHES, 2017).

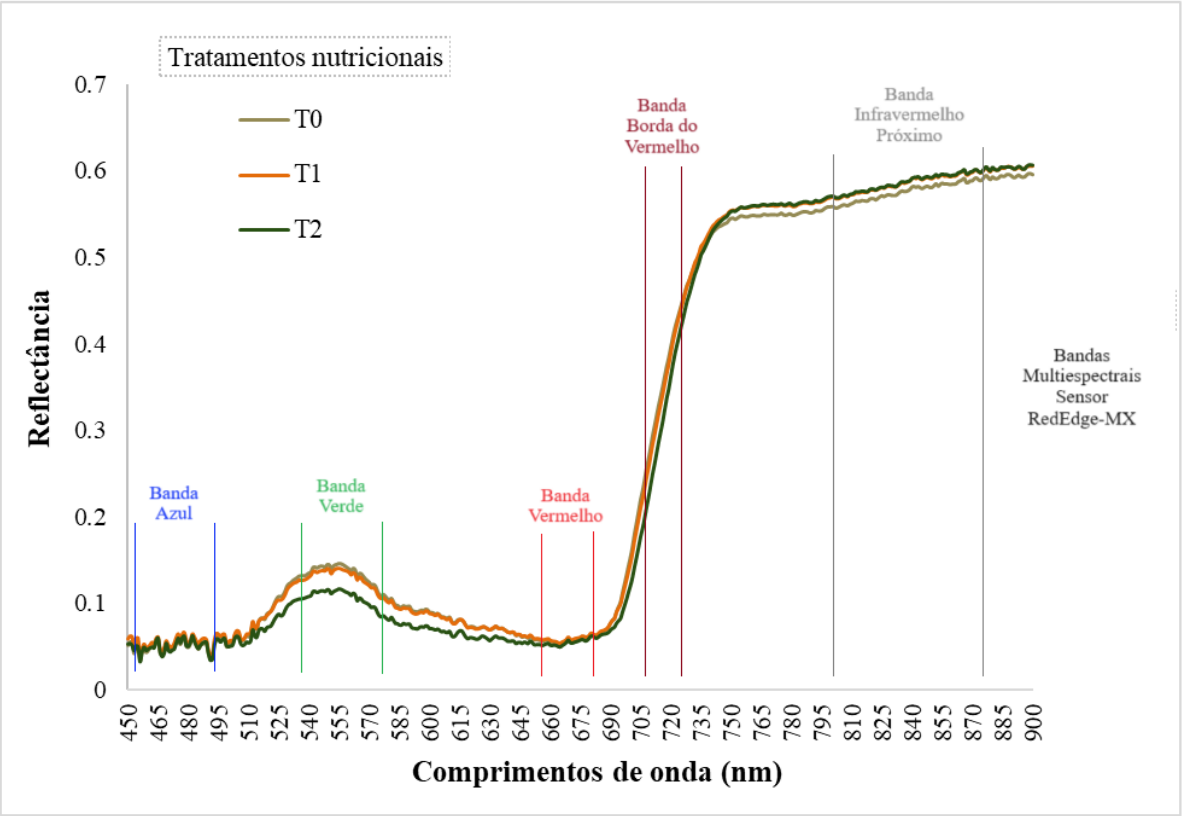


FIGURA 3. Assinaturas espectrais de folhas de *E. saligna* determinadas pelo espectrorradiometro FieldSpec, com indicação das bandas multiespectrais do sensor Micasense RedEdge-MX® (Azul, Verde, Vermelho, Borda do Vermelho e Infravermelho Próximo) em mudas submetidas a três tratamentos nutricionais (T0 - sem adubação, testemunha; T1 - 20% da dose de adubação NPK recomendada; T2 - 50% da dose de adubação NPK recomendada). Spectral signatures of *E. saligna* leaves determined by the FieldSpec spectroradiometer, with indication of the multispectral bands of the Micasense RedEdge-MX® sensor (Blue, Green, Red, Red Edge and Near Infrared) in seedlings subjected to three nutritional treatments (T0 - without fertilization, control; T1 - 20% of the recommended NPK fertilizer dose; T2 - 50% of the recommended NPK fertilizer dose).

De modo geral, as curvas de reflectância para T0, T1 e T2 apresentaram pequenas diferenças visuais entre si. Nas diferentes bandas espectrais de referência, as respostas espectrais das folhas dos três tratamentos apresentaram um padrão de comportamento com baixa refletância nos comprimentos de onda de 455 - 495 nm (banda azul), maior picos de energia refletida nos comprimentos de onda de 540 - 580 nm (banda verde), moderada reflectância nos comprimentos de 600 - 680 nm (banda vermelha) e elevada reflectância, em patamar de maior magnitude, nos comprimentos de onda de 710 - 880 nm (bandas Red-edge e NIR).

Porém, o tratamento testemunha - T0 (sem adubação) foi o que apresentou a menor diferença espectral entre as reflectâncias na região do visível e do infravermelho próximo, sendo este comportamento um indicativo de estresse, o que está coerente com este tratamento nutricional. Já o tratamento T2 (50% da adubação de plantio com NPK recomendada) foi o tratamento que apresentou a maior diferença espectral entre as reflectâncias na região do visível e do infravermelho próximo, característica de uma planta saudável (PONZONI et al., 2012; FORMAGGIO e SANCHES, 2017). Segundo estes autores, as plantas saudáveis refletem mais os comprimentos de onda do infravermelho próximo, para evitar a sua absorção devido aos seus efeitos deletérios. O tratamento T1 (20% da adubação de plantio com NPK recomendada) apresentou uma curva espectral com dupla característica, na região do visível se comportou semelhante ao T0, mas na banda do infravermelho próximo se comportou semelhante ao T2.

Ao analisar as médias dos comprimentos de onda nas bandas de referência, em comparação entre os três tratamentos nutricionais (T0, T1 e T2), observou-se que as variações proeminentes ocorreram com absorções centradas nas bandas espectrais do azul e vermelho para T0, T1 e T2. Já na banda do verde, o tratamento T2 apresentou reflectância mais baixa quando comparado ao T0 e T1, comportamento que se repetiu nas regiões red-edge, tornando-se um pouco maior na banda do NIR (800 - 880 nm).

A reflectância na região visível do espectro é influenciada principalmente pela concentração de pigmentos fotossintéticos, especialmente os de clorofila. Plantas com níveis adequados de N, P e K apresentam geralmente maior vigor vegetativo, proporcionado por teores adequados de clorofila, N e água nos tecidos foliares. Consequentemente, tais plantas apresentam folhas com coloração mais verde, que proporcionaram maior reflectância nessa banda espectral (THOMAS e GAUSMAN, 1977). Essa situação não foi observada nos dados de reflectância das folhas de *E. saligna* no presente estudo para T2, e sim maior reflectância nesta banda para as folhas dos tratamentos T0 e T1.

Ao analisar na literatura diferentes gráficos de reflectância que retratam vegetação/plantas saudável, estressada e severamente estressada, observou-se que para a banda espectral do verde, a curva é menor para a vegetação saudável em relação a vegetação estressada e severamente estressada, a exemplo do descrito por Saunders, Burson e Thompson (1999). Isso indica que plantas sem estresse refletem menos luz na região do visível em relação às plantas com estresse, devido a redução da concentração de clorofila e evolução para clorose. Desta forma, a baixa reflectância na banda verde, não significa necessariamente indicativo de estresse, a exemplo do observado no presente estudo para o tratamento T2. Ainda as baixas reflectâncias nas bandas do vermelho e azul indicam absorção destes comprimentos de ondas pelas clorofilas.

Entretanto, a quantidade de energia absorvida, transmitida ou refletida pelas folhas, que pode diferir dentro da própria espécie devido a fatores como a influência direta e/ou indireta das condições ambientais nessa interação (PONZONI et al., 2012), ou ainda, quando se tem diferenças acentuadas de idade das folhas.

Ao aplicar a ANOVA, verificou-se que existem diferenças significativas ($p < 0,05$) para os tratamentos nas bandas espectrais do visível e red-edge. Somente a banda do NIR não apresentou diferenças entre os tratamentos (Figura 4).

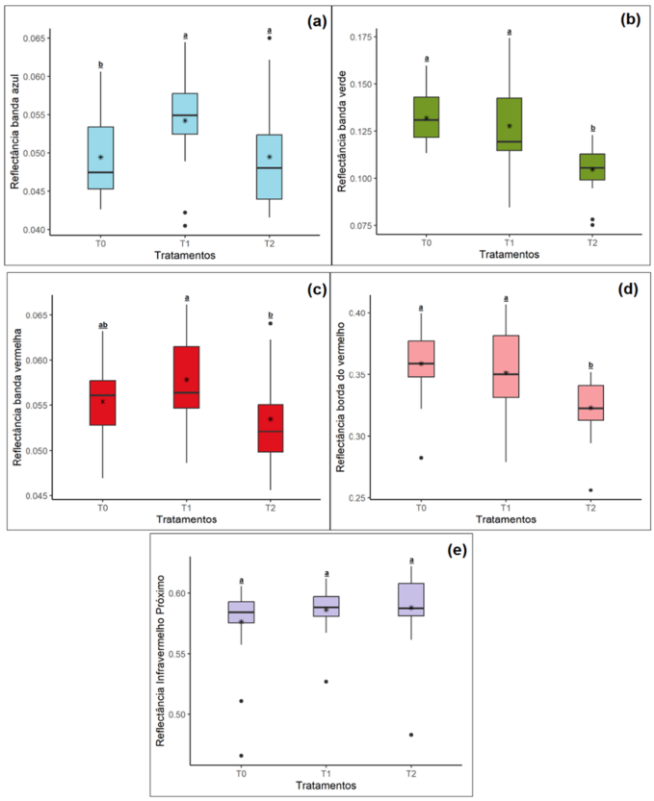


FIGURA 4. Reflectância média foliar nas bandas do azul (a), verde (b), vermelho (c), borda do vermelho (d) e infravermelho próximo(e) para os tratamentos Testemunha (T0), 20% da adubação recomendada (T1) e 50% da adubação recomendada (T2), em mudas de *E. saligna*. Asterisco (*) = média; Barra horizontal dentro da caixa = mediana; Caixa = amplitude interquartis; Suíças = Valores máximos e mínimos não discrepantes; Círculo (?) = valores discrepantes. Letras minúsculas distintas indicam diferença pelo teste de Tukey (p<0,05). Average leaf reflectance in the blue (a), green (b), red (c), red edge (d) and NIR (e) bands, for the Control (T0) treatments, 20% of the recommended fertilization (T1) and 50% of the recommended fertilization (T2), in *E. saligna* seedlings. Different lowercase letters indicate differences according to the Tukey test (p<0.05). Asterisk (*) = average; Horizontal bar inside the box = median; Box = interquartile range; Swiss = Non-discrepant maximum and minimum values; Circle (?) = outliers.

Na banda do azul, os tratamentos T0 e T2 apresentaram médias que não diferiram entre si, somente T1 foi diferente dos demais. No entanto, observa-se que nesta banda em específico, aparentemente houve ruídos nos dados espectrais quando comparados as demais regiões das curvas (Figura 3), o que pode ter interferido neste resultado. Os dados da banda do verde não apresentaram ruído, e o T2 apresentou diferença estatística em relação a T1 e T0. Na banda do vermelho, o T1 apresentou média significativamente diferente de T2, enquanto o T0 está em um grupo intermediário, mas estatisticamente não diferente do T1 e T2. A bando do red-edge apresentou o mesmo comportamento da banda do verde. O tratamento T2 recebeu uma dose maior de nutrientes NPK, e por isso há uma tendência de que este apresente diferenças entre os demais tratamentos, como visto nas bandas espectrais do verde (540 - 580) nm e borda do vermelho (707 - 727 nm). É importante considerar que o ano de 2023 (condução do presente trabalho), foi de forte instabilidade climática no RS, sob efeitos do fenômeno climático-oceânico El Niño, que é caracterizado pelo aquecimento anormal das águas do Oceano Pacífico. Nesse sentido, por se tratar de um ambiente de campo (condições não controladas), que passou por diversas intempéries, como excesso de chuva, geada e dias anormais de calor intenso, tais fatores podem contribuído para os resultados encontrados.

Outro ponto a ser destacado, é que a área de estudo está localizada em um talhão agrícola que já recebeu diversas adubações e correções ao longo dos períodos de plantio das culturas agronômicas.

Silva et al. (2023), ao realizar uma análise de variabilidade espacial e temporal de atributos químicos do solo (P, K, pH e saturação por bases), em três anos (2012, 2017 e 2020), na mesma área de estudo, ressaltou que houve uma evolução significativa na disponibilidade de P no decorrer dos anos, devido às adubações de correção à taxa variada realizadas, com a utilização de adubos fosfatados. No ano de 2020, 87% da área total do talhão foi classificada com nível alto de P (30,1 a 60 mg/dm³), além de também ter apresentado nível alto de K (121 a 240 mg/dm³). Ainda maiores explicações podem ser obtidas com a análise de teores de N, P e K nas folhas para cada tratamento, que demostraram o quanto os mesmos foram absorvidos pelas mudas, para estabelecer relações com os dados de reflectância nas folhas nas bandas consideradas.

Para obter melhor entendimento dos resultados obtidos, foi utilizada a análise multivariada de componentes principais (ACP), que possibilita avaliar todos os dados conjuntamente em uma única análise (Vicini et al., 2018). No gráfico de dispersão das variáveis resultante da ACP (Figura 5), em função dos componentes principais 1 e 2, sendo os mais importantes.

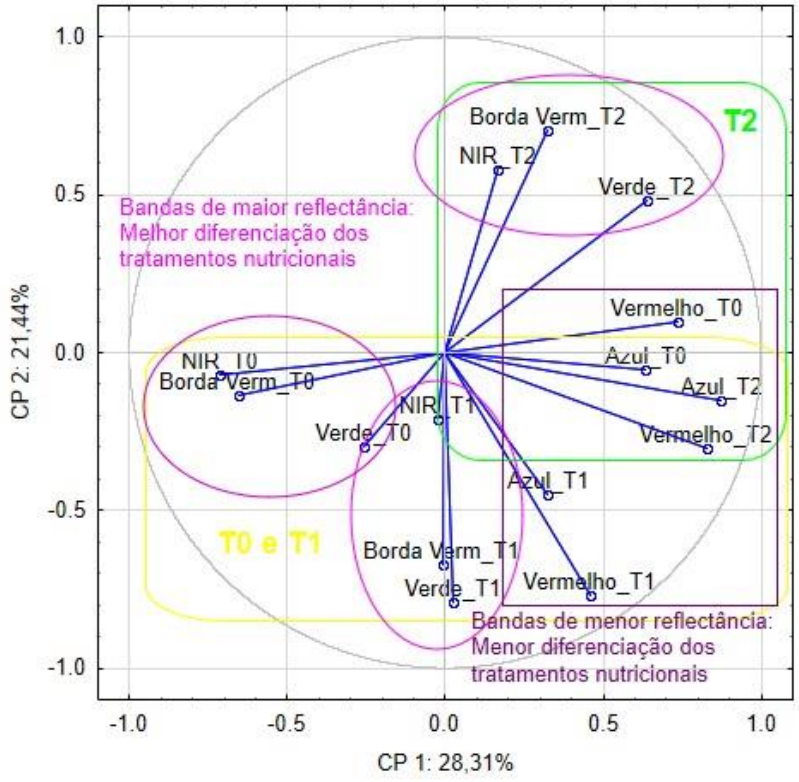


Figura 5. Análise de componentes principais (CP) para a reflectância nas bandas espectrais (azul, verde, vermelho - Verm, borda do vermelho e infravermelho próximo - NIR) em folhas de mudas de *Eucalyptus saligna*, em função dos tratamentos nutricionais (T0 - sem adubação, testemunha; T1 - 20% da dose de adubação NPK recomendada; T2 - 50% da dose de adubação NPK recomendada). Analysis of principal components for reflectance in the spectral bands (blue, green, red, red edge and near infrared) in leaves of *Eucalyptus saligna* seedlings, as a function of nutritional treatments (T0 - without fertilization, control; T1 - 20% of the recommended NPK fertilizer dose; T2 - 50% of the recommended NPK fertilizer dose).

No componente principal 1 (CP 1), que representa 28,31% da variabilidade total dos dados do experimento, houve maior contribuição das bandas espectrais obtidas no T2 (azul - 17,92%, vermelho - 16,12%) e T0 (vermelho - 12,70%, infravermelho próximo - 12,03% e borda do vermelho- 10,10%). Já no CP 2, que representa 21,44% da variabilidade total dos dados do experimento, houve maior contribuição das bandas espectrais obtidas no T1 (verde - 19,41%, vermelho - 18,44% e borda do vermelho - 14,05%) e T2 (borda do vermelho - 15,35%, infravermelho próximo - 10,46%).

Com a ACP foi possível observar melhor diferenciação dos tratamentos nas bandas que apresentam maior reflectância (infravermelho próximo, borda do vermelho e verde) - elipses em lilás (Figura 5), pelo fato de estarem mais distantes e separadas nos diferentes quadrantes. Já nas bandas que apresentam geralmente maior absorção e menor reflectância (azul e vermelho) - retângulo em vinho, a diferenciação dos tratamentos foi menor. O tratamento T2 se diferenciou, com as bandas borda do vermelho, infravermelho próximo e verde, dos tratamentos T0 e T1, que ficaram mais agrupados com a distribuição de suas bandas, incluindo as bandas azul e vermelho do T2.

Destaca-se também que as bandas espectrais simuladas do sensor Micasense RedEdge-MX® foram eficientes em caracterizar e separar os tratamentos em dois grupos diferentes, principalmente nas bandas espectrais do visível (azul, verde e vermelho) e borda do vermelho, que foram capazes de distinguir o T2 com maior eficiência na diferenciação de grupos de plantas, demonstrando o potencial de uso dados espectrais (imagens) gerados por este sensor multiespectral em análises futuras. Dessa forma poderá ser utilizado, por exemplo, aeronaves remotamente pilotadas com sensor multiespectral embarcado, para monitorar estresses abióticos caudados por deficiência e/ou excesso de nutrientes em plantios florestais.

CONCLUSÃO

Os estudos de comportamento espectral, realizados ao nível da folha, são relevantes para detecção remota da sanidade de mudas em plantios florestais, porque possibilitam aumentar a compreensão das complexas interações entre sintomas foliares e como estes podem ser melhor detectados espectralmente. As bandas espectrais simuladas do sensor do Micasense RedEdge-MX® possibilitaram diferenciar mudas clonais de *E. saligna* em dois grupos, decorrentes dos tratamentos nutrionais T2, principalmente nas bandas do verde, vermelho e borda do vermelho, em relação aos tratamentos T1 e T0. Desenvolver e escalonar esses métodos espectrais para imagens de dosséis, que abranjam grandes áreas de plantios florestais de *Eucalyptus sp.* é essencial para testar e reforçar o potencial de imagens de alta resolução espectral e espacial no monitoramento de estresse causado por deficiência nutricional na silvicultura brasileira.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. Os autores também agradecem ao Programa de Apoio à Pós-Graduação (PROAP), ao projeto Advanced Farm 360°, ao projeto Aquarius da Universidade Federal de Santa Maria e à empresa florestal CMPC Brasil.

REFERÊNCIAS

ALVARES, C. A. et al. Köppen's climate classification map for Brazil. **Meteorologische zeitschrift**, v. 22, n. 6, p. 711-728, 2013.

CARTER, G. A.; KNAPPA, A. K. Leaf optical properties in higher plants: linking spectral characteristics to stress and chlorophyll concentration. **American Journal of Botany**, n. 4, v. 8, p.677-684, 2001.

COMISSÃO DE QUÍMICA E FERTILIDADE DO SOLO - RS/SC. **Manual de Calagem e Adubação para os Estados do Rio Grande do Sul e de Santa Catarina**. Sociedade Brasileira de Ciência do Solo - Núcleo Regional Sul. 11. ed. Porto Alegre, 2016. 376 p.

DAMASCENO, A. S. et al. Nutritional monitoring of boron in Eucalyptus spp. in the Brazilian cerrado by multispectral bands of the MSI sensor (Sentinel-2). **Remote Sensing Applications: Society and Environment**, v. 29, p. 100913, 2023. https://doi.org/10.1016/j.rsase.2022.100913

EMBRAPA. Centro Nacional de Pesquisa de Solos. **Sistema Brasileiro de Classificação de Solos**. Brasília: Embrapa -SPI; Rio de Janeiro: Embrapa Solos, 2018. 5ª ed. 355p

FERREIRA, E. B. et al. ExpDes: an R package for ANOVA and experimental designs. **Applied Mathematics**, v. 5, n. 19, p. 2952, 2014.

FORMAGIO, A. R.; SANCHES, I. D. **Sensoriamento remoto em agricultura**. São Paulo: Oficina de Textos, 2017, 288 p.

GRACIA-ROMERO, A. et al. Comparative performance of ground vs. aerially assessed RGB and multispectral indices for early-growth evaluation of maize performance under phosphorus fertilization. **Frontiers in Plant Science**, v. 8, p. 2004, 2017. https://doi.org/10.3389/fpls.2017.02004

IBÁ. Indústria Brasileira De Árvores. **Relatório Anual.** (2022). Disponível: https://www.iba.org/datafiles/publicacoes/relatorios/relatorio-anual-iba2022-compactado.pdf. Acesso em: 07 fevereiro de 2024.

LI, L. et al. Ability of models with effective wavelengths to monitor nitrogen and phosphorus status of winter oilseed rape leaves using in situ canopy spectroscopy. **Field Crops Research**, v. 215, p. 173-186, 2018. https://doi.org/10.1016/j.fcr.2017.10.018

MICASENSE. **Micasense RedEdge Multiespectral Camera TM3**. User Manual. Seatle: Micasense, 2015, 33p.

O´NEILL, M. E.; MATHEWS, K. L. A weighted least squares approach to levene test of homogeneity of variance. Australian e New Zealand Journal Statistical, 42(1):81- 100, 2002.

PINHEIRO, Antônio Lelis et al. Soil fertilization and texture on boron accumulation and wood volume in Corymbia citriodora (Hook) KD Hill & LAS Johnson. **Journal of Experimental Agriculture International**, v. 37, n. 1, p. 1-8, 2019. DOI: 10.9734/JEAI/2019/v37i130255

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. 2º Edição atualizada e ampliada, SãoPaulo, Oficina de textos, 2012.

SAUNDERS, D. F., BURSON, K. R.; THOMPSON, C. K. Model for hydrocarbon microseepage and related near-surface alterations. A.A.P.G. **Bull**, v. 83, p.170-185, 1999.

SILVA JUNIOR, C. A. et al. Is it possible to detect boron deficiency in eucalyptus using hyper and multispectral sensors?. **Infrared Physics & Technology**, v. 116, p. 103810, 2021. https://doi.org/10.1016/j.infrared.2021.103810

SILVA, G. B. et al. Variabilidade espacial e temporal de atributos químicos do solo em área agrícola de Santa Maria/RS. In: **6º Congresso sul-americano de agricultura de precisão e máquinas precisas**, Não-Me-Toque, RS, 2023.

THOMAS, J. R.; GAUSMAN, H. W. Leaf reflectance vs. leaf chlorophyll and carotenoid concentrations for eight crops 1. **Agronomy journal**, v. 69, n. 5, p. 799-802, 1977.

VICINI, L. et al. **Técnicas Multivariadas Exploratórias**: Teoria e Aplicações no Software Statistica. Santa Maria: Editora UFSM, 240 p. 2018.

MAPEAMENTO DA PRODUTIVIDADE UTILIZANDO IMAGENS DE SATÉLITE, PRODUÇÃO da lavoura E FUNÇÃO DENSIDADE DE PROBABILIDADE

Ricardo Canal Filho [1]; Marcelo Chan Fu Wei [1]; Eudocio Rafael Otavio da Silva [1]; José Paulo Molin [2]
[1]Doutorando. Piracicaba - SP, Brasil. Laboratório de Agricultura de Precisão, Departamento de Engenharia de Biossistemas, Escola Superior de Agricultura 'Luiz de Queiroz; [2]Professor Titular. Piracicaba - SP, Brasil. Laboratório de Agricultura de Precisão, Departamento de Engenharia de Biossistemas, Escola Superior de Agricultura 'Luiz de Queiroz

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
A obtenção de mapas de produtividade depende de métodos onerosos para coleta dos dados, calibrações constantes e tecnologias embarcadas em máquinas. Isso limita a adesão a esta tecnologia e o impacto positivo que essa camada de dados pode fornecer ao setor agropecuário. Este trabalho desenvolveu uma metodologia simples para mapear a produtividade de culturas agrícolas, com dados de fácil acesso ao setor produtivo: produção total por área e imagens de satélite. Utilizou-se dois anos consecutivos em duas áreas cultivadas com café e cana-de-açúcar, respectivamente. Gerou-se uma função de distribuição da produção total recuperada da lavoura a partir de imagens de satélite de momentos-chave da fenologia das culturas, por meio da função densidade de probabilidade e índices de vegetação. Os vetores de produtividade gerados foram comparados à produtividade observada e obtida por monitores comerciais, previamente validados. Os resultados reportaram correlação ($p<0,01$) entre o predito e observado para todos os anos e culturas, com erros de predição comparáveis a outros métodos da literatura. A distribuição espacial dos valores também foi consistente entre os métodos, demonstrando potencial robusto para apoiar decisões de gestão. A metodologia apresentada pode ser uma alternativa viável a um amplo espectro de sistemas produtivos, manuais, semimecanizados ou mecanizados, uma vez que independe de maquinário, podendo impulsionar a adoção de práticas de agricultura de precisão.

PALAVRAS-CHAVE: geoestatística; índices de vegetação; sensoriamento remoto

ABSTRACT
The acquisition of yield maps relies on costly methods for data collection, constant calibrations, and technologies embedded in machinery. This limits the adoption of this technology and the positive impact that this layer of data can provide to the agricultural sector. This study developed a simple methodology for mapping the productivity of agricultural crops, using easily accessible data for the productive sector: total production per area and satellite images. Two consecutive years were used in two areas cultivated with coffee and sugarcane, respectively. A distribution function of total recovered crop production was generated from satellite images of key moments in crop phenology, through the probability density function of vegetation indices. The yield vectors generated were compared to the observed yield by previously validated commercial monitors. The results reported significant correlation ($p<0.01$) between predicted and observed yield for all years and crops, with prediction errors comparable to other methods in the literature. The spatial distribution of values was also consistent among methods, demonstrating robust potential to support management decisions. The methodology presented can be a viable alternative to a wide range of productive systems, manual, semi-mechanized, or mechanized, as it does not depend on machinery, thus, it can boost the adoption of precision agriculture practices.

KEYWORDS: ;

INTRODUÇÃO

Os mapas de produtividade são o resultado da interação entre variáveis no espaço e tempo de uma cultura, podendo ser o ponto de partida para diversas investigações e decisões de gestão em busca de maior sustentabilidade produtiva (GEBBERS et al., 2010). Entretanto, a obtenção dessa camada é restrita e dependente da cultura, principalmente por questões relacionadas a métodos onerosos para obtenção dos dados (i.e., coleta manual), necessidade de tecnologias embarcadas em máquinas e calibrações constantes para garantir a qualidade do dado gerado. Todos esses fatores limitam o impacto positivo que essa camada de dados pode fornecer ao setor agropecuário (CARRER et al., 2022; LONGCHAMPS et al., 2022).

Em consequência da baixa adesão dos mapas de produtividade, todo o ciclo da agricultura de precisão (AP) pode ser comprometido. Decisões que dependem da quantidade produzida por área, tanto no tempo como no espaço, tornam-se ineficientes. São exemplos a adubação por exportação da cultura, decisão de reforma de lavouras em culturas perenes ou semiperenes, investigação de problemas pontuais como pragas e doenças, índices de lucratividade, etc.

Dessa forma, como alternativa à obtenção dos dados de produtividade por métodos manuais, semimecanizados ou mecanizados, tem-se os métodos a partir de sensoriamento orbital. Entretanto, a maioria dos estudos com sensoriamento orbital são dependentes da camada de produtividade para realizar a predição, o que novamente torna a sua adoção limitada (AMANKULOVA et al., 2024; NARVEKAR & RAO, 2024). Mas o dado de produção por área/talhão é mais disponível para a maioria dos produtores, bem como dados de sensoriamento orbital têm se popularizado pela facilidade de obtenção. Assim, torna-se oportuno investigar a possibilidade de mapear a produtividade de culturas agrícolas a partir de dados aos quais o setor produtivo possui mais acesso.

Levando em consideração o conhecimento acumulado na literatura quanto a fisiologia do crescimento e desenvolvimento dos cultivos, formulou-se a hipótese de que, utilizando apenas imagens de satélite, a totalização da produção de uma lavoura e funções estatísticas de densidade de probabilidade, é possível redistribuir a produção total de uma área, chegando ao mapa de produtividade daquela cultura.

OBJETIVOS

Dessa forma, o presente trabalho propõe um método simples de obtenção de mapas de produtividade para diferentes culturas agrícolas, que independe de sistemas de colheita.

MATERIAL E MÉTODOS

Para aferir o potencial da técnica em diferentes cenários, o estudo foi realizado: (i) em duas áreas com diferentes cultivos, café e cana-de-açúcar; (ii) dois anos consecutivos, para dar robustez às análises geradas. As informações referentes a cada área estão dispostas na Tabela 1.

TABELA 1. Caracterização das duas áreas utilizadas no presente estudo.

	Área 1	Área 2
Cultura	café arábica	cana-de-açúcar
Variedade	IAC Catuaí 144	SP83-2847
Espaçamento	4,0 m x 0,5 m	1,5 m entrelinhas

Safra/produção	2020 (12ª safra) / 22,31 Mg	2018 (4º corte) / 1974,71 Mg
	2021 (13ª safra) / 15,78 Mg	2019 (5º corte) / 1901,80 Mg
Dimensão	11 ha	32 ha
Localização	Minas Gerais/Brasil	São Paulo/Brasil
Altitude média	1025 m	483 m
Clima (Köppen)[a]	Aw	Cwa

[a] Clima segundo a classificação de Köppen, disponível em ALVARES et al. (2013).

Para gerar os mapas de produtividade pela abordagem proposta, foram necessárias imagens de satélite das áreas de café e cana-de-açúcar. Para a área do cafeeiro, foram utilizadas imagens da plataforma PlanetScope (PLANET TEAM, 2017), com resolução espacial de 3,0 m, do sensor Dove Classic - PS2, produto ortorretificado - Nível 3B. Na área de cana-de-açúcar, o provedor utilizado foi o Sentinel-2 L2A, com resolução espacial de 10,0 m, disponíveis na plataforma EOSDA Land Viewer (eos.com/products/landviewer/). As imagens utilizadas em ambas as áreas foram pré-processadas para a correção atmosférica, de sensor e radiométrica.

Nas duas áreas utilizadas neste estudo, trabalhos anteriores calibraram modelos de aprendizado de máquina para o mesmo talhão, no caso do café (MARTELLO et al., 2022) ou para talhões próximos, dentro da mesma fazenda, no caso da cana-de-açúcar (CANATA et al., 2021). A investigação do presente estudo para selecionar a melhor época de obtenção das imagens de satélite partiu destes resultados, reportados anteriormente. Buscou-se identificar possíveis relações entre imagens de maior componente da variância dos dados de produtividade, e estádios da fisiologia de crescimento e desenvolvimento da cultura. O objetivo foi de utilizar o conhecimento acumulado na literatura para compreender se parâmetros estatísticos poderiam ser relacionados a parâmetros agronômicos.

A análise dos dados foi realizada na linguagem *Python*, no ambiente do programa *Jupyter Notebook* (KLUYVER et al., 2016) e os mapas de superfície foram gerados no sistema de informação geográficao *Quantum Geographic Information System* - QGIS (QGIS DEVELOPMENT TEAM, 2022). As imagens de satélite selecionadas foram utilizadas para calcular os valores do índice de vegetação por diferença normalizada (NDVI) (ROUSE et al., 1974) para cada pixel da imagem (Equação 1). Os valores do NDVI das imagens selecionadas foram, posteriormente, utilizados junto à massa total produzida em cada área, de café ou de cana-de-açúcar, em uma função de distribuição da produtividade.

$$NDVI = \frac{IVp - V}{IVp + V} \quad \text{Eq. (7)}$$

em que: IVp é a reflectância no infravermelho próximo; e V é a reflectância no vermelho visível.

Sendo um dado facilmente disponível ao produtor, a produção total recuperada foi utilizada como valor de entrada da função, sendo a produção final que foi colhida, desconsiderando as perdas. Esse valor foi distribuído utilizando a função densidade de probabilidade (FDP) das imagens de satélite, com o valor de NDVI. A FDP descreve a probabilidade de uma variável aleatória contínua estar sob uma determinada faixa de valores, associando a cada ponto do espaço amostral uma probabilidade de ocorrência (JOHNSON & WICHERN, 2002). Para uma variável aleatória , a probabilidade de que ela esteja em um intervalo é dada pela integral da função densidade de probabilidade nesse intervalo (Equação 2):

$$P(a \leqslant x \leqslant b) = \int_b^a f(x)dx \quad \text{Eq. (8)}$$

em que: P é a probabilidade, x é a variável aleatória, e a e b são os valores mínimo e máximo do intervalo.

Sabendo que a área sob a curva da FDP ao longo do seu domínio é necessariamente igual a 1, é possível distribuir a produção total da lavoura de forma a igualar a massa total produzida à probabilidade total da FDP, gerando um vetor que contém os valores de produção espacializados para cada ponto da lavoura. O vetor resultante foi concatenado com as coordenadas geográficas dos pontos de NDVI das imagens de satélite, para ser interpolado por krigagem ordinária após ajuste do variograma de dependência espacial. O mesmo foi feito com os pontos de produtividade obtidos dos trabalhos de CANATA et al. (2021) e MARTELLO et al. (2022). Os vetores de produtividade distribuída pela metodologia proposta neste trabalho, produtividade observada pelos monitores, bem como os mapas gerados para ambos pela interpolação, foram comparados por meio da correlação de Pearson ($p<0,01$) (r), raiz do erro quadrático médio (RMSE), erro médio absoluto (MAE), e resumo estatístico (distribuição quartílica, desvio padrão (θ), valores médios, mínimos e máximos).

RESULTADOS E DISCUSSÃO

Para o modelo preditivo do café, no estudo de MARTELLO et al. (2022), as imagens de satélite de maior representação da variância dos dados de produtividade foram as imagens de julho e agosto em ambas as colheitas, de 2020 e 2021. Sabe-se que o café possui um ciclo bienal, onde a fase vegetativa dura um ano, e a fase reprodutiva o ano subsequente (CAMARGO & CAMARGO, 2001). Dessa forma, construiu-se o gráfico de fenologia da lavoura de café do presente estudo (Figura 1).

Nota-se que os meses de julho e agosto coincidem exatamente com o período de dormência do cafeeiro na área de estudo. A fase de dormência ocorre após o período vegetativo. A produção do café depende da formação de gemas seriadas e da iniciação floral dessas gemas (evocação) um ano antes da produção. Após iniciadas, as gemas entrarão em dormência durante o período seco do ano, esperando a primeira chuva, que ocorre normalmente na primavera, para quebrar essa dormência e entrar na fase de florescimento/antese (CAMARGO & CAMARGO, 2001; RENA et al., 1986). Dessa maneira, a compreensão da fisiologia do cafeeiro indica que o potencial produtivo da colheita de 2020 estava definido durante os meses de julho e agosto de 2019, e o mesmo ocorreu na colheita seguinte, com o potencial produtivo de 2021 sendo demonstrado durante a fase de dormência de 2020, em julho e agosto. Outros autores, tentando construir modelos preditivos da produtividade a partir de imagens de satélite, também indicaram os meses de julho e agosto como maior componente da variância dos dados (SILVA et al., 2021).

Dessa maneira, os parâmetros agronômicos justificam o padrão estatístico observado na área de estudo. O maior fator da variância da produtividade pelos índices vegetativos de julho e agosto, um ano antes da colheita, indicam um princípio de causalidade. Assim, foram selecionadas as imagens de satélite desta fase fenológica (dormência) para gerar o mapa de produtividade a partir da abordagem proposta neste estudo.

<table>
<tr><th colspan="3">2018</th><th colspan="9">2019</th><th colspan="12">2020</th><th colspan="12">2021</th></tr>
<tr><td colspan="3"></td><td colspan="9">1º ano fenológico</td><td colspan="12">2º ano fenológico</td><td colspan="12">3º ano fenológico</td></tr>
<tr><td colspan="3">3ª fase
Antese</td><td colspan="3">4ª fase
Granação</td><td colspan="3">5ª fase
Maturação</td><td colspan="3">6ª fase
Senes-cência</td><td colspan="6">1ª fase
Formação de gemas seriadas</td><td colspan="6">2ª fase
Evocação floral</td><td colspan="3">3ª fase
Antese</td><td colspan="3">4ª fase
Granação</td><td colspan="3">5ª fase
Maturação</td><td colspan="3">6ª fase
Senes-cência</td></tr>
<tr><td colspan="9">Período reprodutivo</td><td colspan="3">Morte de ramos</td><td colspan="9">Período vegetativo</td><td colspan="3">Dormên-cia</td><td colspan="9">Período reprodutivo</td><td colspan="3">Morte de ramos</td></tr>
<tr><td>Set</td><td>Out</td><td>Nov</td><td>Dez</td><td>Jan</td><td>Fev</td><td>Mar</td><td>Abr</td><td>Mai</td><td>Jun</td><td>Jul</td><td>Ago</td><td>Set</td><td>Out</td><td>Nov</td><td>Dez</td><td>Jan</td><td>Fev</td><td>Mar</td><td>Abr</td><td>Mai</td><td>Jun</td><td>Jul</td><td>Ago</td><td>Set</td><td>Out</td><td>Nov</td><td>Dez</td><td>Jan</td><td>Fev</td><td>Mar</td><td>Abr</td><td>Mai</td><td>Jun</td><td>Jul</td><td>Ago</td></tr>
<tr><td colspan="9">Período vegetativo</td><td colspan="3">Dormên-cia</td><td colspan="9">Período reprodutivo</td><td colspan="3">Morte de ramos</td><td colspan="9">Período vegetativo</td><td colspan="3">Dormên-cia</td></tr>
<tr><td colspan="6">1ª fase
Formação de gemas seriadas</td><td colspan="6">2ª fase
Evocação floral</td><td colspan="4">3ª fase
Antese</td><td colspan="3">4ª fase
Granação</td><td colspan="3">5ª fase
Maturação</td><td colspan="3">6ª fase
Senes-cência</td><td colspan="6">1ª fase
Formação de gemas seriadas</td><td colspan="6">2ª fase
Evocação floral</td></tr>
</table>

FIGURA 1. Fases fenológicas do cafeeiro identificadas para a área utilizada no presente estudo, durante as safras de 2020 e 2021. Adaptado de Camargo e Camargo (2001).

Para o modelo preditivo da produtividade da cana-de-açúcar, no estudo de CANATA et al. (2021), o maior componente da variância da produtividade foi dado pelo sensoriamento orbital nas fases de perfilhamento da cultura, principalmente ao final, próximo à fase de crescimento dos colmos. Sabe-se que o perfilhamento culmina na formação da touceira. Essa fase é quem define a população de colmos que será colhida (GASCHO & SHIH, 1983). No auge do perfilhamento, logo antes da fase de crescimento dos brotos, o NDVI de uma lavoura de cana-de-açúcar cresce rapidamente, até atingir um pico e estabilizar, posteriormente decrescendo (ZHENG et al., 2021). BONNET (2013) comenta que, como a produtividade ótima depende da densidade de colmos na área, o perfilhamento é a fase crítica do processo de aumento do potencial produtivo. SINGELS et al. (2005) demonstraram que, apesar de duas cultivares obterem diferentes números de perfilhos, o pico do perfilhamento foi atingido após o mesmo tempo térmico acumulado, indicando que há um momento na lavoura de cana-de-açúcar onde o potencial produtivo foi atingido. A partir daí o crescimento e maturação dos colmos depende da população que foi gerada até essa fase de fechamento do dossel.

Denota-se, portanto, que o forte componente da variância das imagens de satélite do perfilhamento para explicar os dados de produtividade pode ter fundamento em relações agronômicas da cultura. Baseado nisso, optou-se pelo teste da distribuição da produção com as imagens desse estádio fenológico. Investigadas as relações agronômicas entre os dados, da mesma forma que para a área de café, foram selecionadas as imagens de satélite do auge do perfilhamento para gerar o mapa de produtividade a partir da abordagem proposta neste estudo.

O resumo estatístico dos dados demonstra que a estratégia de distribuição da produtividade pela FDP obteve resultados próximos aos observados pelos monitores de produtividade (Tabela 2). A média da produtividade foi exatamente a mesma entre os dados observados e preditos para todos os quatro cenários testados (dois anos de colheita do café, e dois anos de colheita de cana). Já o θ apresentou a tendência de ser menor entre os dados preditos do que para os dados observados. Isso pode ser explicado, parcialmente, pela tendência na distribuição da produtividade pela FDP ter perdido os valores extremos (máximos) de produtividade na área de cana-de-açúcar. Na área de café, ocorreu o contrário, a predição pela FDP aumentou a faixa de produtividade em ambos os anos, reduzindo os valores mínimos e aumentando os máximos observados. Entretanto, a análise dos quartis demonstra que o comportamento estatístico dos dados representa de forma fidedigna o observado pelos monitores. Por exemplo, para a colheita de 2020, na área de café, os valores observados e preditos dos quartis 0,25, 0,50 e 0,75 foram 1,63/1,71, 2,04/2,08 e 2,54/2,42 Mg ha^{-1}, respectivamente. Os demais anos, de café e cana-de-açúcar, mostram comportamento semelhante.

Para uso na agricultura, a proximidade entre os valores quartílicos da produtividade observada e predita possui importância sumária, pois indica que a distribuição dos valores na área seguiu um padrão definido, em concordância com os valores observados pelos monitores. Isso permite a tomada de decisão correta para gestão da lavoura a partir das informações que o mapa pode gerar.

TABELA 2. Resumo estatístico dos vetores de produtividade observada e predita para as áreas de café e de cana-de-açúcar, em ambas as safras utilizadas no presente estudo.

	Café				Cana-de-açúcar			
	2020		2021		2018		2019	
	Obs	Pred	Obs	Pred	Obs	Pred	Obs	Pred
	Mg ha^{-1}							

média	2,05	2,05	1,45	1,45	60,13	60,13	57,91	57,91
θ	0,50	0,44	0,43	0,35	7,79	5,59	7,84	5,04
mín	1,06	0,54	0,65	0,42	43,23	44,30	40,16	40,74
1º qrt	1,63	1,71	1,06	1,17	54,65	56,48	52,67	54,37
2º qrt	2,04	2,08	1,47	1,51	58,84	59,95	56,47	58,13
3º qrt	2,54	2,42	1,81	1,72	63,63	63,17	61,30	61,39
máx	2,87	3,11	2,23	2,33	84,34	75,86	92,66	71,76

Obs: observado; Pred: predito; média: média aritmética; θ: desvio padrão; mín: valor mínimo observado; 1º qrt: quartil de 25% dos dados; 2º qrt: quartil de 50%; 3º qrt: quartil de 75%; máximo: valor máximo observado.

A Tabela 3 mostra os parâmetros de correlação, RMSE e MAE entre o vetor de produtividade do monitor e do vetor de produtividade predito a partir deste estudo. A estratégia proposta neste estudo foi capaz de mapear a produtividade com r significativo a 99% para ambas as culturas, café e cana-de-açúcar, nos dois anos avaliados para cada área. O mapeamento da produtividade do café apresentou os maiores valores de r, de 0,89 e 0,80, e a cana de açúcar apresentou r de 0,72 e 0,64.

Na análise do erro de predição, a área de café apresentou RMSE e MAE de 0,22/0,18 e 0,26/0,21 Mg ha^{-1} para as colheitas de 2020 e 2021, respectivamente. Em comparação, MARTELLO et al. (2022) utilizaram modelos *random forest* (RF) com imagens NDVI de julho e agosto, obtendo RMSE e MAE de 0,21/0,16 e 0,25/0,19 Mg ha^{-1} para as colheitas de 2020 e 2021. Por outro lado, SILVA et al. (2021), ao prever a produtividade de café com imagens orbitais e dados de campo, alcançaram RMSE de 0,60 a 0,64 Mg ha^{-1}.

Na área de cana-de-açúcar, a abordagem deste estudo resultou em RMSE e MAE de 5,43/4,36 Mg ha^{-1} na colheita de 2018 e 6,00/4,64 Mg ha^{-1} na colheita de 2019. CANATA et al. (2021), ao prever a produtividade conjunta dos dois anos com modelos RF e dados de NDVI em talhões adjacentes ao utilizado neste estudo, encontraram RMSE e MAE de 5,39/4,18 Mg ha^{-1}.

A vantagem do método proposto neste trabalho, entretanto, é a simplicidade de dados de entrada para realizar a predição. Enquanto um modelo RF necessita calibração com um monitor de produtividade, para posterior predição, a estratégia de distribuição pela FDP utiliza somente os dados coletados por satélite, de fácil acesso, e a produção total da lavoura em que se deseja gerar o mapa de produtividade.

TABELA 3. Parâmetros estatístico entre a produtividade observada com os monitores de produtividade e a produtividade predita considerando imagens de satélite, produção total recuperada da lavoura e distribuição pela função densidade de probabilidade.

	Café		Cana-de-açúcar	
	2020	2021	2018	2019
r	0,89**	0,80**	0,72**	0,64**
RMSE	0,22	0,26	5,43	6,00
MAE	0,18	0,21	4,36	4,64

r: Correlação de Pearson, **correlação significativa a 99%; RMSE: raiz do erro quadrático médio, Mg ha^{-1}; e MAE: erro médio absoluto, Mg ha^{-1}

Nos mapas da lavoura de café, observa-se o mesmo comportamento espacial entre o observado pelos monitores e o predito pela estratégia adotada neste estudo. É possível identificar um contraste entre os dois anos, demarcando zonas distintas. Entretanto, não são zonas de alta e baixa produtividade, mas possivelmente zonas de diferente comportamento fisiológico das plantas. A produção do café é governada pelo fenômeno da bienalidade, onde, apesar de crescimento vegetativo e reprodutivo ocorrerem concomitantemente, em um ano o maior dreno é o vegetativo, e no outro o reprodutivo (CAMARGO & CAMARGO, 2001). Dessa maneira, todos os tratos culturais têm de ser orientados por esse fenômeno, uma vez que as diferentes fases fenológicas geram demandas nutrifisiológicas distintas.

Essa peculiaridade pôde ser notada apenas a partir dos mapas de produtividade, uma vez que o monitoramento da produção total da lavoura levaria o gestor à conclusão habitual de que toda a lavoura possuía o mesmo comportamento fisiológico. Isso reforça a grande valia da estratégia apresentada neste estudo. O mapa de produtividade do monitor embarcado em colhedora só poderia ser obtido por essa tecnologia, em sistemas mecanizados e por produtores que adotem essa estratégia. O mapa distribuído pela FDP utiliza apenas a informação usual da totalização da produção no talhão e imagens de satélite de livre acesso, e permite mesmo aos produtores de sistemas manuais ou semimecanizados a terem a espacialização da produção da sua lavoura, tomando as decisões mais assertivas a partir disso.

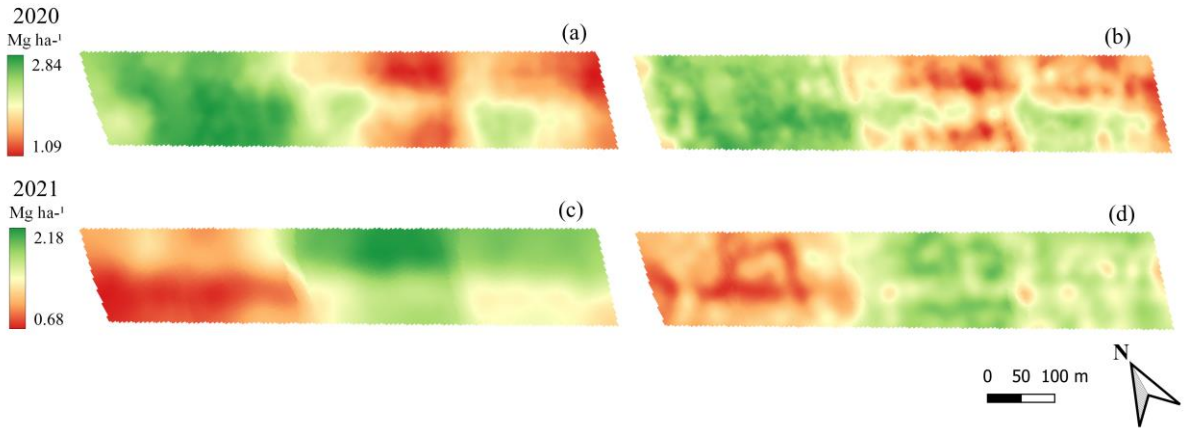


FIGURA 2. Caracterização espacial da produtividade do café, obtidas por krigagem ordinária, para as colheitas de 2020 e 2021. (a) e (c) dados do monitor de produtividade embarcado na colhedora; (b) e (d) produtividade predita com imagens de satélite, produção total do talhão e distribuição pela função densidade de probabilidade dos vetores.

Os mapas da lavoura de cana-de-açúcar também demarcaram o mesmo comportamento espacial entre o observado pelos monitores e predito pela estratégia deste estudo. Diferente da lavoura de café, aqui podem ser observadas zonas bem definidas que se repetem entre os dois anos, de maior e menor produtividade na área. Apesar da distribuição pela FDP ter suavizado os pontos de maior produtividade da área, nota-se que isso ocorreu em poucos pontos da lavoura, e a distribuição quartílica acompanhou de forma robusta os valores do monitor, gerando mapas semelhantes para ambas as estratégias. Ambos os mapas permitiriam ao gestor da área direcionar atividades que dependem da massa de cana produzida, como adubação de reposição, investigação de falhas e ataques de pragas e doenças, reforma do canavial, entre outras. Mais uma vez, é reforçada a utilidade da estratégia proposta neste estudo. Os mapas foram gerados apenas com a produção total da área e o monitoramento orbital. Uma estratégia que não necessita embarcar novas tecnologias nas máquinas,

nem adequar a frente de trabalho das máquinas em campo, reduzindo o operacional necessário para chegar no mapeamento da produtividade.

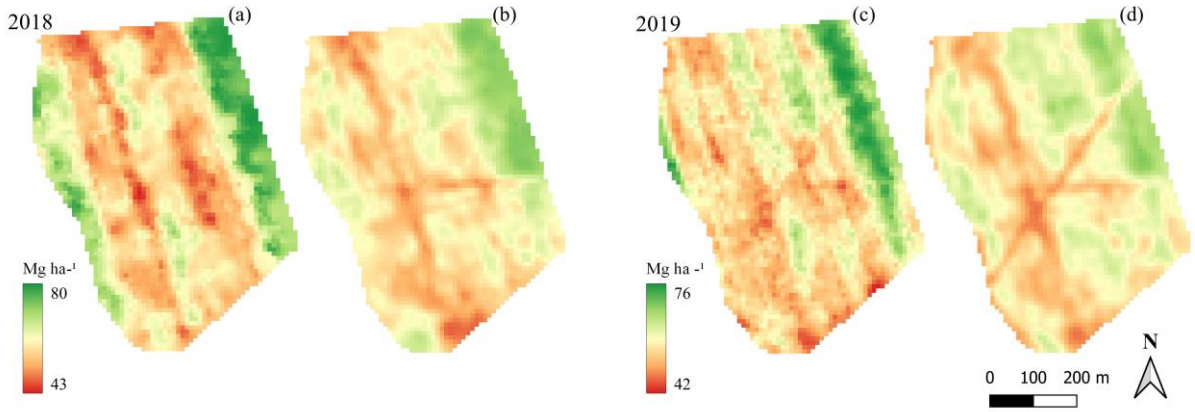


FIGURA 3. Caracterização espacial da produtividade da cana-de-açúcar, obtidas por krigagem ordinária, para as colheitas de 2018 e 2019. (a) e (c) dados do monitor de produtividade da colhedora; (b) e (d) produtividade predita com imagens de satélite, produção total do talhão e distribuição pela função densidade de probabilidade dos vetores.

Futuros trabalhos podem testar essa estratégia para outras culturas, ou utilizando diferentes sensores imageadores e regiões do espectro eletromagnético que tenham interações relevantes com as culturas agrícolas. Espera-se que essa estratégia auxilie sistemas produtivos onde o uso de monitores de produtividade embarcado em máquinas agrícolas, seja dificultoso, ou impossibilitado. Uma estratégia simples e eficaz para mapear a produção das culturas agrícolas em uma lavoura, capaz de popularizar o uso de mapas de produtividade, pode ser um grande precursor das práticas de AP.

CONCLUSÃO

Neste trabalho, funções estatísticas de densidade de probabilidade foram utilizadas para gerar mapas de produtividade para duas culturas agrícolas, café e cana-de-açúcar. A estratégia desenvolvida utiliza dados de simples obtenção como entrada da função: a totalização da produção combinada a imagens de satélite de momentos relevantes da fisiologia da cultura. Essa estratégia demonstrou capacidade de mapear a produtividade para ambas as culturas, café e cana-de-açúcar. A estabilidade temporal do método também demonstrou robustez, uma vez que ela funcionou em dois anos consecutivos para as duas áreas/culturas. Os resultados indicam esta como uma alternativa viável a um amplo espectro de sistemas produtivos. Uma vez que independe de maquinário, pode ser útil a sistemas manuais, semimecanizados, ou mesmo em sistemas mecanizados em que monitores de produtividade apresentem desvantagens para sua adoção.

AGRADECIMENTOS

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pelo financiamento ao primeiro autor, processo nº 2023/04638-1*.

*As opiniões, hipóteses e conclusões ou recomendações expressas neste material são de responsabilidade do(s) autor(es) e não necessariamente refletem a visão da FAPESP.

REFERÊNCIAS

Alvares, C.A.; Stape, J.L.; Sentelhas, P.C.; de Moraes Gonçalves, J.L.; Sparovek, G. Köppen's Climate Classification Map for Brazil. **Meteorologische zeitschrift**, v.22, p.711-728, 2013.

Amankulova, K.; Farmonov, N.; Omonov, K.; Abdurakhimova, M.; & Mucsi, L. Integrating the Sentinel-1, Sentinel-2 and topographic data into soybean yield modelling using machine learning. **Advances in Space Research**, v.73, p.4052-4066, 2024.

Bonnett, G. D. Developmental stages (phenology). **Sugarcane: physiology, biochemistry, and functional biology**, p.35-53, 2013.

Camargo, Â.P.D., & Camargo, M.B.P.D. Definition and outline for the phenological phases of arabic coffee under Brazilian tropical conditions. **Bragantia**, v.60, p.65-68, 2001.

Canata, T. F., Wei, M. C. F., Maldaner, L. F., & Molin, J. P. Sugarcane yield mapping using high-resolution imagery data and machine learning technique. **Remote Sensing**, v.13(2), p.232, 2021.

Carrer, M.J., Filho, H.M. de S., Vinholis, M. de M.B., Mozambani, C.I. Precision agriculture adoption and technical efficiency: An analysis of sugarcane farms in Brazil. **Technological Forecasting and Social Change** 177, 2022.

Gascho, G. J.; Shih, S. F. Sugarcane. In: Teare, I. D.; Peet, M. M. (Ed.). **Crop-water relations**. New York: Wiley-Interscience. p. 445-479, 1983.

Gebbers, R., Adamchuk, V.I. Precision agriculture and food security. **Science**, v.327, n.5967, p.828-831, 2010.

Johnson, R. A., & Wichern, D. W. Applied multivariate statistical analysis - 6th edition. New Jersey: Pearson Education, 2007.

Kluyver, T., Ragan-Kelley, B., Pérez, F., Granger, B. E., Bussonnier, M., Frederic, J., & Willing, C. (2016). Jupyter Notebooks-a publishing format for reproducible computational workflows. **Elpub**, v. 2016, p. 87-90, 2016.

Longchamps, L., Tisseyre, B., Taylor, J., Sagoo, L., Momin, A., Fountas, S., Manfrini, L., Ampatzidis, Y., Schueller, J.K., Khosla, R. Yield sensing technologies for perennial and annual horticultural crops: a review. **Precision Agriculture**, v.23, p.2407-2448, 2022.

Martello, M., Molin, J. P., Wei, M. C. F., Canal Filho, R., & Nicoletti, J. V. M. Coffee-yield estimation using high-resolution time-series satellite images and machine learning. **AgriEngineering**, v.4(4), p.888-902, 2022.

NARVEKAR, C.; RAO, M. Agricultural Productivity Improvement-Role Of Ai And Yield Prediction Using Machine Learning. In: **Precision Agriculture for Sustainability**. Apple Academic Press, p. 83-97, 2024.

Planet Team. Planet Application Program Interface. In Space for Life on Earth; Planet Team: San Francisco, CA, USA. Available online: https://api.planet.com. 2017.

QGIS Development Team. Quantum Geographic Information System. Open-Source Geospatial Foundation Project. Available online: http://qgis.osgeo.org. 2022

Rena, A.B.; Maestri, M. Fisiologia Do Cafeeiro. Cultura Do Cafeeiro: Fatores Que Afetam a Produtividade. Piracicaba, SP: **Associação Brasileira para Pesquisa da Potassa e do Fosfato**, 1986.

Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. Monitoring vegetation systems in the Great Plains with ERTS. **NASA Special Publications**, v.351(1), p.309, 1974.

Silva, P. A. A., Alves, M. C., da Silva, F. M., & Figueiredo, V. C. Coffee yield estimation by Landsat-8 imagery considering shading effects of planting row's orientation in center pivot. **Remote Sensing Applications: Society and Environment,** v.24, p.100613, 2021.

Singels, A., Smit, M. A., Redshaw, K. A., & Donaldson, R. A. The effect of crop start date, crop class and cultivar on sugarcane canopy development and radiation interception. **Field crops research**, v.92(2-3), p.249-260, 2005.

Zheng, Y., Luciano, A. C. S., Dong, J., & Yuan, W., 2021. High-resolution map of sugarcane cultivation in Brazil using a phenology-based method. **Earth System Science Data Discussions**, p.1-25, 2021.

MONITORAMENTO DE PLANTIOS DE EUCALIPTO COM IMAGENS DE SATÉLITE

NORTON BORGES JUNIOR [1,2]; RODRIGO SOUZA BARNECHE [4]; TIAGO RAFAEL DOS SANTOS [3]
[1]Doutorando. Avenida Roraima, Santa Maria/RS. UFSM; [2]Pesquisador. Rua São Geraldo, 1800. CMPC; [3]Analista de SIG. Rua São Geraldo, 1800. CMPC; [4]Coordenador de Informação Patrimonial. Rua São Geraldo, 1800. CMPC

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
O eucalipto é a espécie arbórea mais plantada no RS, visando principalmente a produção de madeira para a indústria de celulose e para o abastecimento de serrarias. Garantir a máxima produtividade dos plantios é de suma importância nos dias de hoje, visto que há uma grande limitação na disponibilidade de terra para os projetos de reflorestamento, principalmente por questões do zoneamento ambiental. Desta forma, este estudo teve por objetivo avaliar o uso de ferramentas de sensoriamento remoto no monitoramento dos plantios de eucalipto. Plantios com mais de 2 anos de idade foram monitorados através de imagens do satélite Sentinel 2. O parâmetro utilizado de monitoramento foi o Índice de Vegetação de Diferença Normalizada (NDVI). O sistema detectou a redução do NDVI nos plantios por diferentes causas, como pragas, doenças e injúrias abióticas, como a seca de árvores causadas por déficit hídrico. O sensoriamento remoto com imagens de satélite mostrou-se uma importante ferramenta para o monitoramento em plantios de eucalipto.

PALAVRAS-CHAVE: Eucalipto; Dano abiótico; Produtividade

ABSTRACT
Eucalyptus is the most planted tree species in RS, mainly aimed at producing wood for the cellulose industry and supplying sawmills. Ensuring maximum productivity of plantations is extremely important nowadays, as there is a great limitation in the availability of land for reforestation projects, mainly due to environmental zoning issues. Therefore, this study aimed to evaluate the use of remote sensing tools in monitoring eucalyptus plantations. Plantings over 2 years old were monitored using images from the Sentinel 2 satellite. The monitoring parameter used was the Normalized Difference Vegetation Index (NDVI). The system detected the reduction of NDVI in plantations due to different causes, such as pests, diseases and abiotic injuries, such as tree drought caused by water deficit. Remote sensing with satellite images proved to be an important tool for monitoring eucalyptus plantations.

KEYWORDS: Eucalyptus; Abiotic damage; Productivity

INTRODUÇÃO

O plantio do eucalipto vem aumentando significativamente no Brasil, devido à sua excelente adaptação às condições de clima e de solo aqui existentes. Em 2021, a área total de árvores plantadas totalizou 9,93 milhões de hectares, um crescimento de 1,9% em relação ao dado revisado de 2020, que era de 9,75 milhões de hectares. O setor de árvores plantadas é responsável por 1,1% de toda riqueza gerada no país e 6,2% do PIB (Produto Interno Bruto) industrial. Os plantios estão localizados, principalmente, em Minas Gerais (24%), São Paulo (17%), Mato Grosso do Sul (15%), Bahia (11%) e Rio Grande do Sul (6%), o que representa 72,3% das plantações florestais brasileiras. O setor energético, de celulose e papel, moveleiro e da construção civil são os principais usuários da madeira produzida pelo eucalipto, de acordo com o Relatório da Associação da Indústria Brasileira de Árvores (IBÁ, 2022).

O monitoramento dos plantios é fundamental para conhecer os problemas que ocorrem, como a ocorrência de pragas e doenças afetando a produtividade, danos causados por eventos climáticos como vendaval, para a tomada de decisão gerencial. O sensoriamento remoto mostra-se como uma ferramenta importante pois possibilita o monitoramento de extensas áreas em pouco tempo, com imagens gratuitas de satélites disponibilizadas pelo menos a cada 7 dias (LEMES et. al., 2021).

OBJETIVOS

O objetivo do presente estudo foi avaliar o uso de um sistema utilizando imagens de satélite para realizar o monitoramento de plantios de eucalipto, visando a detecção de problemas pelo Índice de Vegetação de Diferença Normalizada (NDVI).

MATERIAL E MÉTODOS

Plantios de *Eucalyptus* spp. com mais de dois anos de idade, localizados no Estado do Rio Grande do Sul, foram monitorados por imagens do satélite Sentinel 2, através da ferramenta Monitora.

As seguintes cenas foram usadas: 22HCJ, 22HCK, 22HBK, 21HYE, 21XJF, 21JYF, 22JBL, 22JBM, 22KJU. 21JYJ, 22JEM. Foram utilizadas 120 imagens durante o período de janeiro a dezembro de 2023.

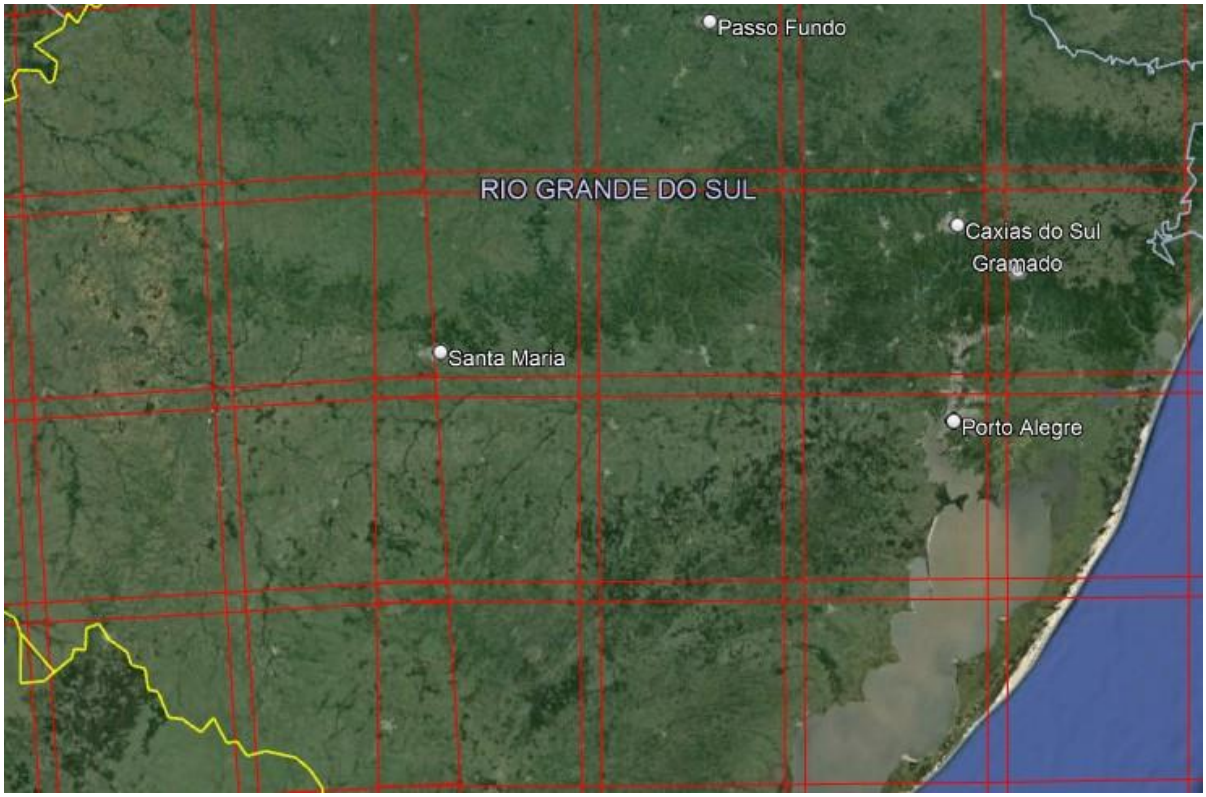


Figura 1. Cenas do Satélite Sentinel 2 utilizadas para o monitoramento.

As seguintes bandas foram empregadas: Sentinel 2 - NDVI: NIR = 8; RED = 4. Sentinel 2 - RGB: RED = 4; GREEN = 3; BLUE = 2.

A resolução espacial das imagens foi de 10 metros = NIR, RED, GREEN e BLUE.

Alertas foram emitidos quando o NDVI do plantio apresentava um valor menor que a média esperada, sendo que todos os alertas foram posteriormente analisados em campo.

RESULTADOS E DISCUSSÃO

O sistema monitorou em 2023 uma área total de 2.176.598 ha, durante 12 meses. No total, foram emitidos 1.700 alertas para validação em campo. Na Figura 2, podemos observar a área total (ha) de alertas emitidos em cada mês.



Figura 2. Área (ha) com alertas emitidos por mês em 2023.

Todos os alertas foram emitidos para as unidades de manejo (talhões) que apresentaram o valor médio de NDVI menor que o limiar configurado. Na Figura 3A, tem-se uma representação de um talhão com a ocorrência de uma área com baixo NDVI, representada pela coloração laranja, enquanto a cor verde representa a área com NDVI acima do limiar configurado. Na Figura 3B, observamos a tonalidade da vegetação na imagem de satélite.

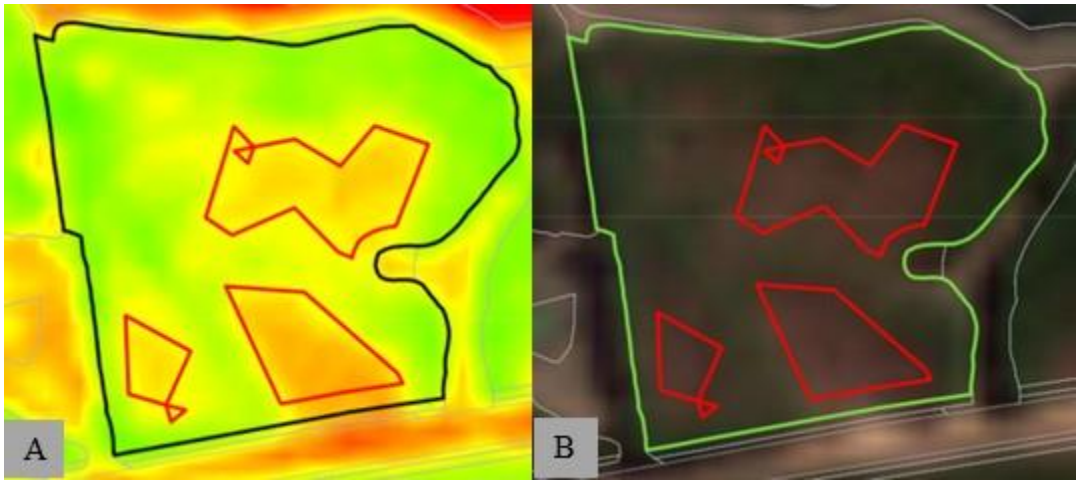


Figura 3A. Polígonos com NDVI abaixo do limiar configurado. Figura 3B. Imagem de satélite.

Após a verificação em campo, observou-se que os alertas estavam relacionados a vários fatores bióticos e abióticos, como ocorrência de pragas, doenças e injúrias abióticas. O principal problema observado em campo, através dos alertas emitidos, foi a ocorrência de plantios de eucalipto apresentando árvores completamente secas, afetadas por déficit hídrico associado com solos rasos (Figura 2). Este problema representou 32% da área de alertas emitidos, e está relacionado principalmente ao forte período de estiagem ocorrido no Rio Grande do Sul durante o verão de 2023.

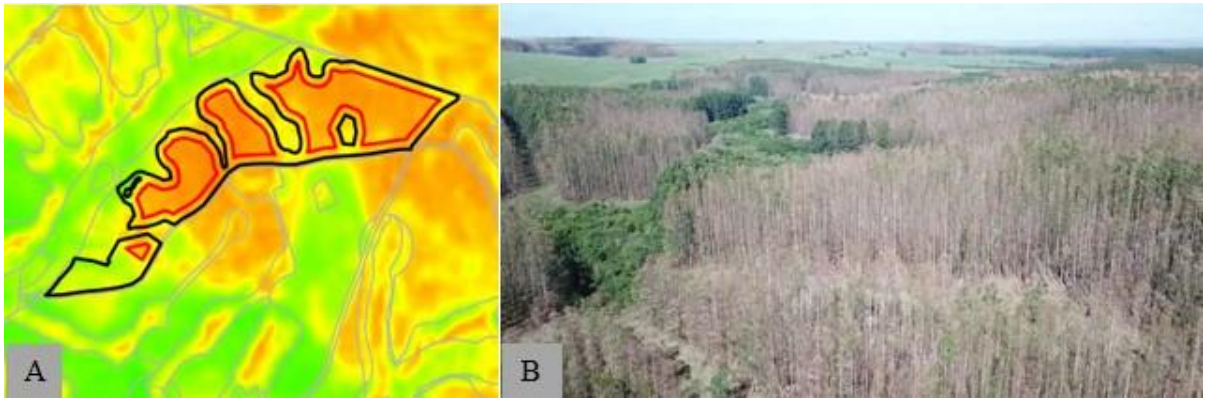


Figura 4A. Polígonos com NDVI abaixo do limiar. Figura 4B. Plantio com sintomas de déficit hídrico.

O uso do sensoriamento remoto com imagens de satélite mostrou uma boa aplicação para a previsão de danos causados por pragas e doenças, empregando-se índices de vegetação como o NDVI, conforme já relatado por OUMAR & MUTANGA (2012) e WANTROBA et. al. (2023).

A ferramenta de monitoramento dos plantios com imagens de satélite apresentou bons resultados para a detecção de anomalias nas áreas de reflorestamento, podendo ser empregada para monitorar o estado fitossanitário dos plantios de eucalipto.

CONCLUSÃO

O monitoramento de plantios de eucalipto utilizando sistemas de sensoriamento remoto é uma alternativa viável para produtores florestais, principalmente de médio e grande porte, com baixo custo e boa precisão.

AGRADECIMENTOS

A empresa CMPC por disponibilizar a área de estudo.

REFERÊNCIAS

IBÁ - INDÚSTRIA BRASILEIRA DE ÁRVORES. **Relatório Ibá 2022**. São Paulo, 2022. Disponível em: https://iba.org/datafiles/publicacoes/relatorios/relatorio-anual-iba2022-compactado.pdf.

LEMES, P.G.; ZANUNCIO, J.C. **Novo Manual de Pragas Florestais Brasileiras**. Montes Claros: Instituto de Ciências Agrárias da Universidade Federal de Minas Gerais, 2021.

OUMAR, Z.; MUTANGA, O. Using WorldView-2 bands and indices to predict bronze bug (*Thaumastocoris peregrinus*) damage in plantation forests. **International Journal of Remote Sensing.** Vol. 34, No. 6, 2013, 2236-2249.

WANTROBA, K.L; et.al. 2023. Detecção de ataque por insetos-praga em plantios de *Eucalyptus* spp. por meio de índices de vegetação. **Revista Observatorio de la economia Latinoamericana**, Curitiba, v.21, n.9, p. 11497-11515.

POTENCIAL DE SENSOR LiDAR EM DISPOSITIVOS iOS NA MENSURAÇÃO FLORESTAL

Bruna Roque Mazzaro [5]; Lúcio de Paula Amaral [1]; Sally Deborah Pereira da Silva [3]; Liane de Souza Weber [2]; Regiane Aparecida Ferreira [4]

[1]Docente. Av. Roraima 1000 - Prédio 44J Sala 213, Santa Maria-RS, CEP 97.105-900. Universidade Federal de Santa Maria (PPGAP; PPGEF; DER-CCR); [2]Docente. Av. Roraima 1000 - Prédio 44J Sala 218, Santa Maria-RS, CEP 97.105-900. Universidade Federal de Santa Maria (DER-CCR); [3]Doutoranda. Av. Roraima 1000 - Prédio 44 Sala 5255, Santa Maria-RS, CEP 97.105-900. Universidade Federal de Santa Maria (PPGEF); [4]Egressa Mestrado AP, Eng. Florestal. Av. Roraima 1000 - Prédio 70 Bloco F Sala 211-A, Santa Maria-RS, CEP 97.105-900. Colégio Politécnico da Universidade Federal de Santa Maria (PPGAP); [5]Engenheira Florestal, Egressa Graduação (UFSM Sede). Av. Roraima 1000 - Prédio 42 Sala 3131, Santa Maria-RS, CEP 97.105-900. Universidade Federal de Santa Maria

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A evolução da tecnologia LiDAR é um marco significativo no campo do sensoriamento remoto para a mensuração florestal. A convergência entre o sensoriamento remoto e os dispositivos iOS, como iPads e iPhones, redefine o cenário dos dispositivos pessoais. Este estudo explora a crescente importância da tecnologia LiDAR na transformação das práticas tradicionais de mensuração florestal. A análise de precisão do sensor LiDAR em dispositivos iOS, por meio do aplicativo ForestScanner, revelou consistências entre as observações de Diâmetro a Altura do Peito (DAP) a partir da circunferência medida com fita métrica (medida de referência) e as estimativas de DAP com o LiDAR iOS com os aplicativos ForestScanner e *CloudCompare* para *Pinus sp.*. A realização do teste t demonstrou não haver diferenças significativas entre o DAP medido e estimado com o LiDAR iOS. O estudo não apenas evidencia a constante evolução na mensuração florestal, mas também denota a tendência promissora da integração dessas tecnologias, que impulsionam avanços na avaliação de recursos florestais, contribuindo para pesquisas futuras e para o aprimoramento contínuo desta tecnologia, para aplicação de conceitos de floresta de precisão, derivados da agricultura de precisão.

PALAVRAS-CHAVE: ForestScanner; LiDAR iOS; CloudCompare

ABSTRACT

The evolution of LiDAR technology is a significant milestone in the field of remote sensing for forest measurement. The convergence between remote sensing and iOS devices such as iPads and iPhones redefines the personal device landscape. This study explores the growing importance of LiDAR technology in transforming traditional forest measurement practices. The accuracy analysis of the LiDAR sensor on iOS devices, through the ForestScanner application, revealed consistencies between the observations of Breast Diameter at Height (DBH) from the circumference measured with a tape measure (reference measurement) and the DAP estimates with o LiDAR iOS with the ForestScanner and CloudCompare apps for Pinus sp.. Performing the t-test demonstrated that there were no significant differences between the DAP measured and estimated with the iOS LiDAR. The study not only highlights the constant evolution in forest measurement, but also denotes the promising trend in the integration of these technologies, which drive advances in the assessment of forest resources, contributing to future research and the continuous improvement of this technology, for the application of forest concepts of precision, derived from precision agriculture.

KEYWORDS: ForestScanner; LiDAR iOS; CloudCompare

INTRODUÇÃO

No contexto da mensuração florestal, a busca pela exatidão das estimativas é essencial, e deve envolver a minimização de erros relacionados ao tamanho da amostra, variabilidade da unidade amostral e método de seleção das unidades, além de erros não amostrais, como falhas e calibração em equipamentos/sensores (SOARES et al., 2011). Apesar dos avanços, a necessidade de equipes especializadas e custos significativos persiste. Nesse sentido, a aplicação de técnicas de sensoriamento remoto, como o LiDAR (*Light Detection and Ranging*) aerotransportado e terrestre, destacam-se ao instrumentalizar os procedimentos de mensuração florestal e também, ao superar obstáculos encontrados por métodos tradicionais, especialmente em áreas de difícil acesso e densamente vegetadas.

O princípio de funcionamento do LiDAR baseia-se na emissão de pulsos de laser em direção à superfície, com uma frequência de alta repetição. Com base no tempo de retorno, na posição do sensor e na orientação do raio, é possível calcular a posição tridimensional do objeto (BALTSAVIAS, 1999). No setor florestal, tem sido utilizado para mapear terrenos sob coberturas vegetais, estimar variáveis dendrométricas, como diâmetro, área basal, volume e biomassa (DALLA CORTE et al., 2020; INDIRABAI et al., 2020; BROWN et al., 2022).

Mais recentemente, desde o ano de 2020, a aplicação de sensores LiDAR tem sido integrada em dispositivos móveis que operam com o sistema iOS, sendo equipados com sensores LiDAR com varredura de até cinco metros. Pesquisas exploratórias já destacam o potencial desses dispositivos em diversas áreas, como digitalização industrial em 3D, documentação patrimonial e mensuração florestal (VOGT et al., 2021; MURTIYOSO et al., 2021; GOLLOB et al., 2021). A convergência entre tecnologias de sensoriamento remoto e a popularidade dos dispositivos móveis abre novas perspectivas para a gestão florestal, ambiental e agrícola, proporcionando não apenas uma plataforma acessível, mas também desafiando paradigmas estabelecidos.

OBJETIVOS

Dessa forma, o presente trabalho teve por objetivo avaliar a precisão do sensor LiDAR em dispositivo móvel com sistema operacional iOS para a obtenção de dados oriundos de inventários florestais, mais precisamente medidas de Diâmetro a Altura do Peito em centímetros (DAP), que caracterizam a produtividade das plantações florestais e subsidiam a gestão florestal.

MATERIAL E MÉTODOS

Área de Estudo: O estudo foi realizado em duas áreas de plantio de *Pinus* sp. localizado no Campus Sede da Universidade Federal de Santa Maria (UFSM), município de Santa Maria, Rio Grande do Sul, Brasil (Figura 1).

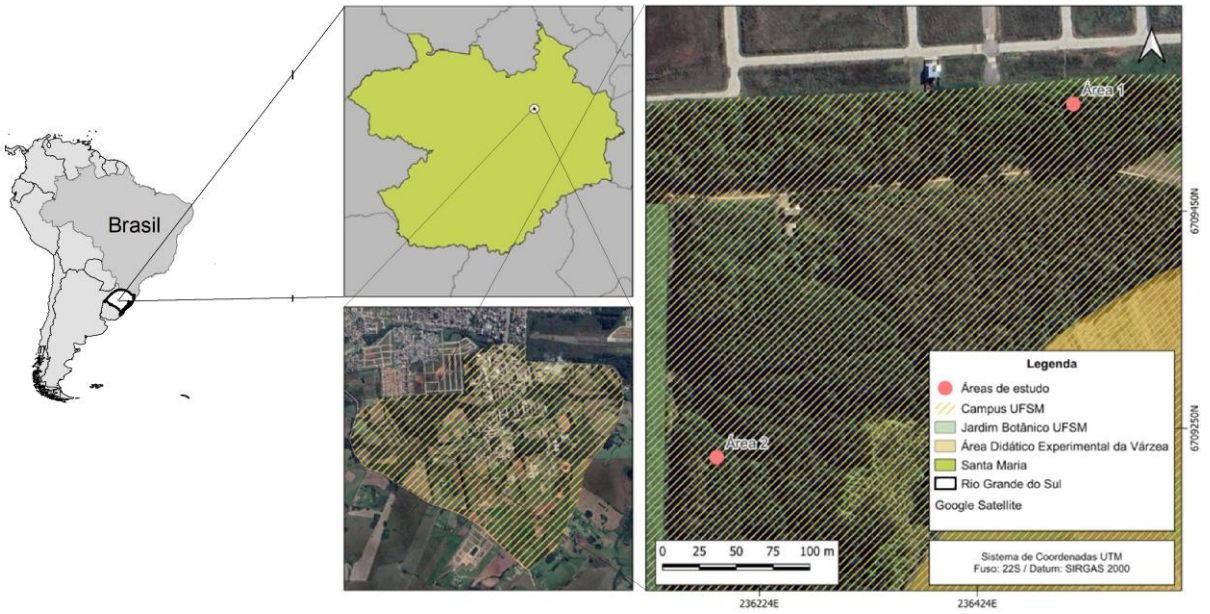


FIGURA 1. Plantio de *Pinus* sp. localizado na Universidade Federal de Santa Maria, Santa Maria - RS, Brasil. Planting of *Pinus* spp. located at the Federal University of Santa Maria, Santa Maria - RS, Brazil.

Coleta e processamento de dados: Os dados de campo foram coletados no mês de novembro de 2023 em dois pontos distintos do Campus. Para a aquisição das coordenadas, utilizou-se o aplicativo Formiga Super, versão 45.1, instalado no *smartphone* iPhone 14 PRO, 256 GB, IOS 17.4.1. No primeiro ponto, denominado Área 1, foram coletados dados de Circunferência à Altura do Peito (CAP) de cinco árvores isoladas, utilizando fita métrica de 1,50 m (precisão de 1 mm). Simultaneamente, as coordenadas dessas árvores foram capturadas, seguidas pelo escaneamento realizado com o sensor LiDAR iOS com o aplicativo *ForestScanner*, ambos presentes no mesmo *smartphone*. Em cada árvore, o dispositivo foi posicionado a uma distância de cinco metros, sendo apontado o sensor para a região de medida do diâmetro no fuste (DAP) e também para o solo, ao mesmo tempo foi realizado um caminhamento em 360º em torno de cada árvore.

No segundo ponto (Área 2), o mesmo procedimento foi aplicado, com um transecto nas entrelinhas do plantio, simulando uma unidade amostral de área fixa (tradicionalmente utilizada nos inventários florestais), onde foram realizados dois escaneamentos, no sentido logitudinal e transversal da unidade amostral, em 37 árvores. Em seguida, foi mensurado o CAP com fita métrica. As informações de CAP, das árvores de ambas as áreas, foram tabuladas em planilha eletrônica, e transformados em diâmetro à altura do peito (DAP), pela divisão do CAP medido pelo valor de π (3,14...) obtendo-se o DAP calculado para cada árvore.

Para a manipulação dos arquivos de nuvens de pontos obtidos com sensor LiDAR iOS, utilizou-se o *software CloudCompare*, instalado em computador com sistema operacional windows 10, 64 bits. Após a inicialização do programa, os dados foram importados, permitindo a visualização tridimensional das árvores escaneadas. Com o uso da ferramenta *PointPicking* no *CloudCompare*, a distância entre dois pontos foi medida, sendo estimados os diâmetros das árvores isoladas na altura do DAP - 1,30 m a partir do solo (FIGURA 2). No caso da área 2, onde se tinham 37 árvores, foi possível estimar o diâmetro de 20 árvores, devido a forma como o escaneamento foi realizado.

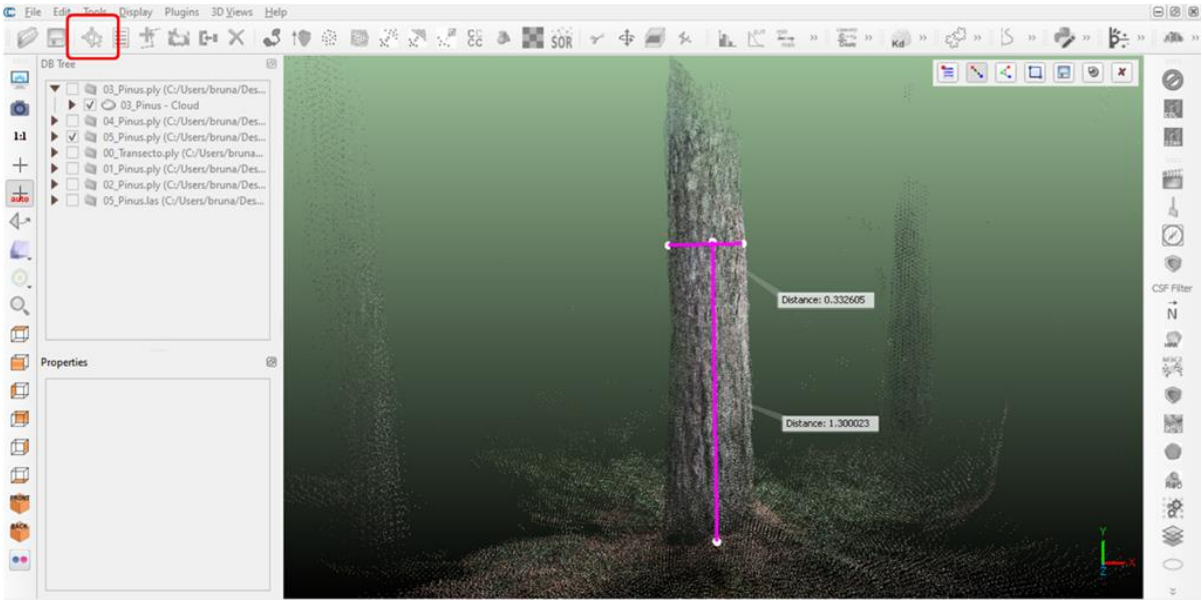


FIGURA 2. Estimativa de diâmetros das árvores de *Pinus* sp. com a ferramenta *PointPicking* do *software CloudCompare*. Estimation of diameters of Pinus sp. trees. with CloudCompare software's PointPicking tool

Análise estatística: Após o processamento dos arquivos e estimativa dos dados de DAP, foi realizada a estatística descritiva e o teste t ao nível de significância 95% ($\alpha = 0,05$) e análise de correlação de Pearson ($p = 0,05$), no *software* SigmaPlot versão 13, para comparar os dados das amostras.

RESULTADOS E DISCUSSÃO

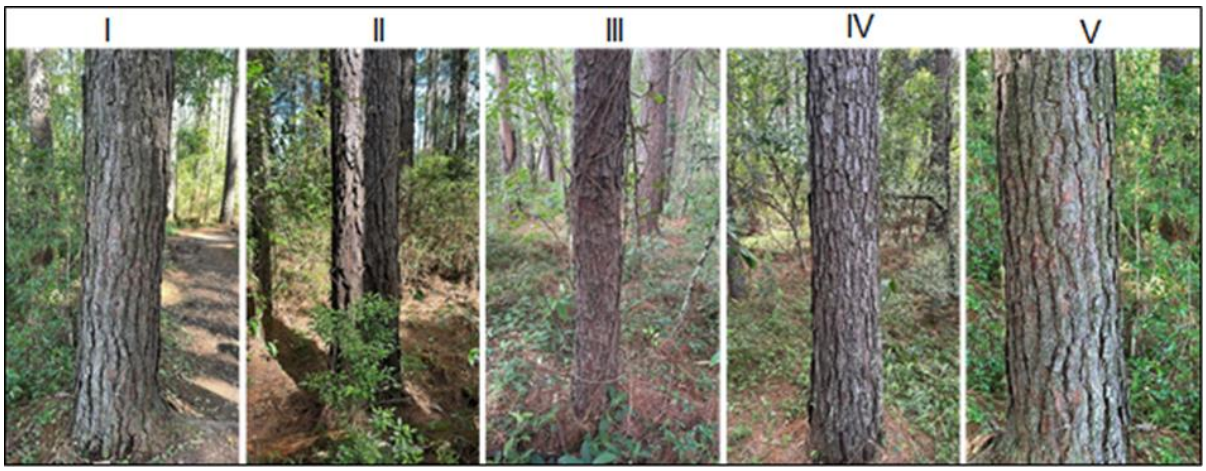
Os dados de circunferência à altura do peito (CAP medido) medidos com fita métrica, transformados para diâmetro à altura do peito (DAP calculado) e o DAP estimado com dados do sensor LiDAR iOS para as árvores de *Pinus* sp. isoladas na Área 1 estão apresentados na Tabela 1.

TABELA 1. Valores de DAP obtido a partir do CAP medidos com fita métrica nas árvores de *Pinus sp.* isoladas e DAP estimado na nuvem de pontos geradas com o sensor LiDAR iOS no iPhone 14 Pro no software CloudCompare para na área 1, Santa Maria, RS, Brasil. DAP values obtained from CAP measured with a tape measure on *Pinus sp* trees isolated and DAP estimated in the point cloud generated with the LiDAR iOS sensor on the iPhone 14 Pro in the CloudCompare software for area 1, Santa Maria, RS, Brazil.

N	CAP medido (cm)	DAP calculado (cm)	DAP estimado (cm) com sensor LiDAR iOS
1	123,6	39,3	37,8
2	83,2	26,5	30,3
3	53,1	16,9	17,5
4	103,7	33,0	33,2
5	135,7	43,2	42,6

Legenda: N = Número de observações; CAP = Circunferência à altura do peito (cm); DAP - Diâmetro à altura do peito (cm).

Na Figura 3 (I, II, III, IV e V), é possível visualizar as árvores de *Pinus* sp. isoladas da Área 1, em que foram obtidos os dados de CAP e realizado o perfilamento laser. Destaca-se a significativa presença de sub-bosque na área 1, evidenciando a influência de regeneração natural na obtenção dos dados e, posteriormente, na qualidade da nuvem de pontos obtida e nas respectivas estimativas de DAP.



Legenda: I a V = correspondem as árvores de *Pinus sp.* mensuradas, respesctivamente, de 1 a 5.

FIGURA 3. Árvores de *Pinus* sp. isoladas da Área 1, cujos dados de Circunferência a Altura do Peito foram aferidos com fita métrica (medida de referência) e escaneadas com LiDAR iOS para estimativa de DAP. *Pine* trees sp. isolated from Area 1, whose data from Circumference to Chest Height were measured with a tape measure (reference measure) and scanned with LiDAR IOS to estimate DBH.

A análise estatística descrtiva (Tabela 2) sugere haver similaridade nos dados de DAP obtidos pelas duas formas consideradas no estudo. O Valor do teste t para dados de DAP calculados a partir do CAP mensurado com fita métrica e estimados com LiDAR iOS apresentou valor de -0,0795 (p-valor 0,939; GL 8) demonstrou que não existiu diferença significativa, a 95% de probabilidade. Para realizar o teste t, foram observadas para os dados, teste positivo para homogeneidade de variâncias (p-valor 0,674) e normalidade (p-valor 0,318). A correlação de Pearson foi de 0,9844 (p-valor 0,0023). Esses resultados indicam a viabilidade da utilização do sensor LiDAR em dispositivos iOS como uma alternativa confiável para a determinação do DAP, fornecendo possibilidades para práticas de mensuração florestal. A diferença aferida entre os valores médios do DAP calculado apartir do CAP mensurado com fita métrica em relação as estimativas de DAP com o sensor LiDAR iOS e aplicativos foi de 0,5 cm.

TABELA 2. Estatística descritiva e comparação dos dados de DAP medido e estimado no software CloudCompare a partir da varredura LiDAR iOS para árvores de *Pinus sp*. isoladas na área 1, Santa Maria, RS, Brasil. Descriptive statistics and comparison of measured and estimated DBH data in CloudCompare software from LiDAR iOS scanning for *Pinus sp* trees. isolated in area 1, Santa Maria, RS, Brazil.

DAP calculado (cm) - CAP fita métrica		**DAP estimado (cm) - LiDAR IOS Iphone 14 Pro**	
Média	31,78	Média	32,28
Erro padrão	4,68	Erro padrão	4,24
Mediana	33,00	Mediana	33,20
Moda	amodal	Moda	amodal

Desvio padrão	10,46	Desvio padrão	9,49
Variância da amostra	109,44	Variância da amostra	90,05
Curtose	-0,69	Curtose	1,25
Assimetria	-0,56	Assimetria	-0,96
Intervalo	26,30	Intervalo	25,10
Mínimo	16,90	Mínimo	17,50
Máximo	43,20	Máximo	42,60
Soma	158,90	Soma	161,40
Nº de observações	5,00	Nº de observações	5,00
Nível de confiança (95%)	12,99	Nível de confiança (95%)	11,78

Legenda: CAP = Circunferência à altura do peito (cm); DAP - Diâmetro à altura do peito (cm).

Para a Área 2, que representa uma unidade amostral de área fixa, a minimização da interferência proporcionada pela presença de regeneração natural foi um elemento chave na obtenção de uma nuvem de pontos mais precisa e refinada, considerando as 20 árvores modeladas, influenciando diretamente na qualidade da aquisição de dados. Mas quanto ao caminhamento realizado na unidade amostral, melhorias podem ser realizadas, pois 17 árvores não foram bem modeladas. A forma de caminhamento com sensores LiDAR TLS (Terrestrial Laser Scanning) interfere na modelagem de árvores (PERUGIA et al., 2019; KU?ELKA et al., 2022). Possívelmente, o tamanho da parcela também tenha causado influência. Na Tabela 3, foi possível ter uma visão detalhada dos dados obtidos durante o levantamento, com informações relacionadas ao CAP e DAP obtidos.

TABELA 3. Valores de CAP medidos com fita métrica transformados em diâmetro e DAP estimado no *software CloudCompare* a partir da varredura LiDAR iOS para árvores de *Pinus* sp. na área 2, Santa Maria, RS, Brasil. CAP values measured with a tape measure transformed into diameter and DAP estimated in the CloudCompare software from LiDAR iOS scanning for *Pinus* sp trees. in area 2, Santa Maria, RS, Brazil.

N	**CAP medido (cm)**	**DAP calculado (cm)**	**DAP estimado (cm) sensor LiDAR**
1	84,7	27,0	21,8
2	81,7	26,0	27,6
3	85,0	27,1	26,0
4	78,9	25,1	26,1
5	62,3	19,8	21,1
6	103,1	32,8	33,5
7	95,4	30,4	31,1
8	85,3	27,2	28,9

9	92,2	29,3	28,7
10	90,4	28,8	29,1
11	90,8	28,9	28,1
12	42,1	13,4	14,6
13	90,8	28,9	26,7
14	91,9	29,3	28,2
15	94,3	30,0	31,6
16	71,7	22,8	21,5
17	73,7	23,5	24,0
18	118,5	37,7	36,8
19	89,9	28,6	27,6
20	97,6	31,1	32,4

Legenda: N = Número de observações; CAP = Circunferência à altura do peito (cm); DAP - Diâmetro à altura do peito (cm).

Na Figura 4 (I, II e III), pode-se visualizar a área onde foi simulada a unidade amostral com a realização dos transectos nas entrelinhas. Observa-se uma notável melhoria na qualidade da nuvem de pontos nesta área específica, evidenciada pela ausência de sub-bosque, conforme a representação gráfica gerada através do aplicativo *ForestScanner* (IV).

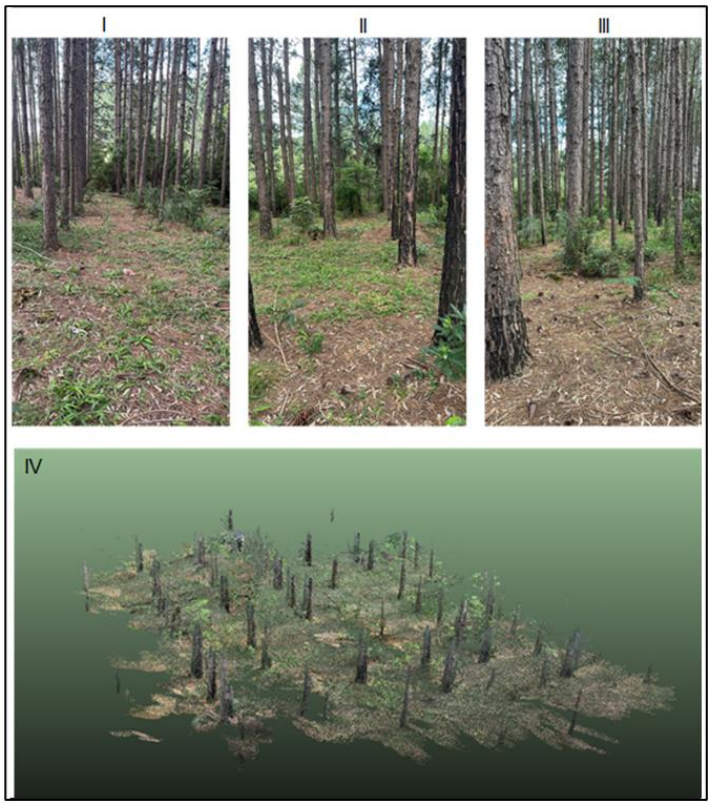


FIGURA 4. Árvores de *Pinus* sp. medidas na unidade amostral simulada (I, II e III) e um exemplo de vista frontal da nuvem de pontos obtida pelo LiDAR iOS gerada no *ForestScanner* (IV), para a área 2, Santa Maria, RS, Brasil. *Pine* trees sp. measurements in the simulated sampling unit (I, II and III) and an example of a frontal view of the point cloud obtained by LiDAR iOS (IV) and generated *ForestScanner* (IV) for area 2, Santa Maria, RS, Brazil.

A baixa ocorrência de vegetação de sub-bosque na área 2 contribuiu para uma aquisição mais precisa e nítida dos dados, resultando em uma representação mais fidedigna do terreno e das características dendrométricas das árvores. Por meio da estatística descritiva (Tabela 4) foi possível observar a semelhança dos dados de DAP obtidos pelas duas formas testadas. O Valor do teste t para dados de DAP calculados a partir do CAP mensurado com fita métrica e estimados com LiDAR iOS apresentou valor de 0,0726 (p-valor 0,942; GL 38) e demonstrou não existir diferença significativa, a 95% de probabilidade. Para realizar o teste t, foram observadas para os dados, teste positivo para homogeneidade de variâncias (p-valor 0,841) e normalidade (p-valor 0,053). A correlação de Pearson foi de 0,944 (p-valor <0,0001). Estes resultados demonstram a viabilidade da aplicação do LiDAR em dispositivos iOS como uma alternativa confiável para a medição de DAP, fornecendo possibilidades para práticas de mensuração florestal. A diferença aferida entre os valores médios do DAP calculado a partir do CAP mensurado com fita métrica em relação as estimativas de DAP com o sensor LiDAR iOS e aplicativos foi de 0,11 cm (Tabela 4).

TABELA 4. Estatística descritiva e comparação dos dados de DAP calculado e estimado no software CloudCompare a partir da varredura lidar para árvores de Pinus sp. na área 2, Santa Maria, RS, Brasil. Descriptive statistics and comparison of measured and estimated DBH data in CloudCompare software from lidar scanning for Pinus sp trees. in area 2, Santa Maria, RS, Brazil.

DAP medido (cm) - CAP fita métrica		**DAP estimado (cm)** - LiDAR IOS Iphone 14 Pro	
Média	27,38	Média	27,27
Erro padrão	1,12	Erro padrão	1,12
Mediana	28,70	Mediana	27,85
Moda	28,90	Moda	27,60
Desvio padrão	5,01	Desvio padrão	5,00
Variância da amostra	25,12	Variância da amostra	25,02
Curtose	2,73	Curtose	1,12
Assimetria	-0,90	Assimetria	-0,59
Intervalo	24,32	Intervalo	22,20
Mínimo	13,40	Mínimo	14,60
Máximo	37,72	Máximo	36,80
Soma	547,59	Soma	545,38
Nº de indivíduos	20,00	Nº de indivíduos	20,00
Nível de confiança (95%)	2,35	Nível de confiança (95%)	2,34

CV%	18,31	CV%	18,34

A Figura 5 (A e B), os valores médios de DAP obtidos pelas duas formas consideradas no estudo, nas áreas I e II, para avaliar estatisticamente pelo teste t, a precisão do sensor LiDAR em relação aos dados de DAP obtidos pela transformação do CAP mensurado com fita métrica. Observou-se que não existiu diferença significativa, a 95% de probabilidade, entre as duas formas de obtenção de DAP para *Pinus sp*., nas duas áreas utilizadas no estudo.

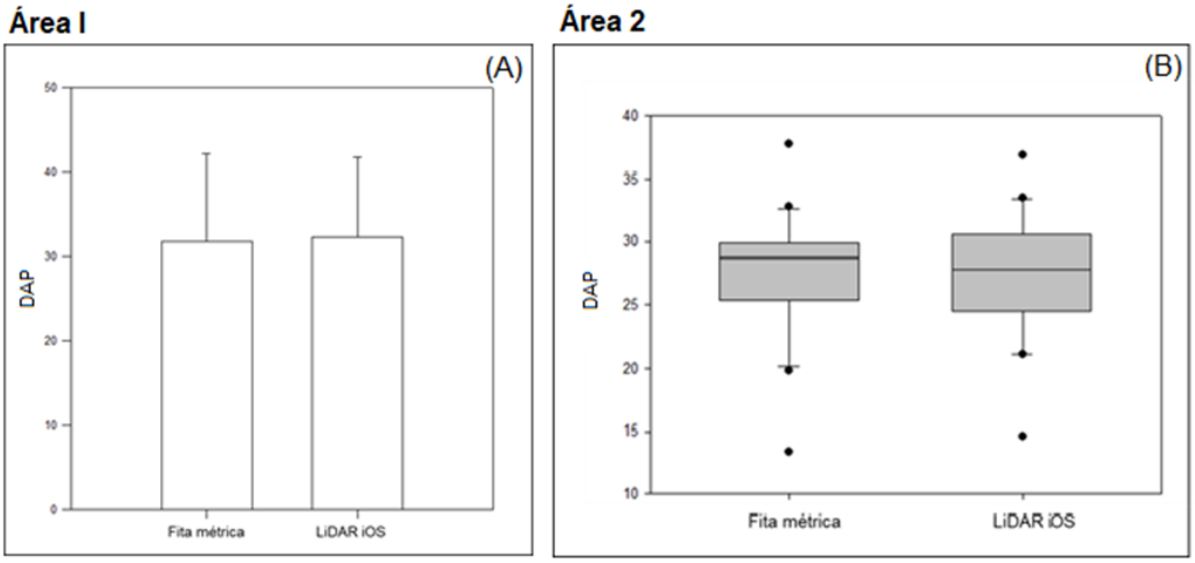


FIGURA 5. Valores médios pelo teste t para avaliação estatística da precisão do DAP estimado com dados LiDAR iOS em comparação com o DAP obtido pela transformação do CAP mensurado com fita métrica, para as áreas 1 (A) e box plot para a área 2 (B). Result of the t test for statistical evaluation of the accuracy of the LiDAR sensor in comparison with the DBH by transforming the CAP measured with a tape measure, for areas 1 (A) and area 2 (B).

As nuvens de pontos tridimensionais obtidas com o LiDAR iOS para árvores individuas (Figura 2) e para a unidade amostral (Figura 4.IV) foram semelhantes as obtidas por Gollob et al. (2021), em modelagens de árvores realizada em um inventário florestal realizado em Viena - Áustria utilizando o sensor LiDAR no Apple iPad Pro 11 256 GB com IOS 14.4.1 (4ª. geração) no conjunto de câmeras na face posterior, com distância de operação de 5m entre sensor e alvos. Os autores também observaram 97,3% de detecção de árvores e RMSE de 3,13 cm para a estimativa de DAP (DAP limite de inclusão de 10 cm) em relação a um outro sensor, o personal laser scanning (PLS) modelo GeoSlan ZEB HORIZON (300.000 pontos por segundo, distância de operação 100 m, precisão de ±3 cm, campo de visada angular 360° x 270° - sensor profissional), que detectou 99,5% das árvores com RMSE de 1,59 cm para a estimativa do DAP. No presente trabalho foi possível utilizar 20 de 37 arvores detectadas, devido a presença de sub-bosque na unidade amostral e também possivelmente pela forma de caminhamento realizado na unidade.

A análise das variáveis dendrométricas nas Áreas 1 e 2, conforme observado, está alinhada com as observações de Tatsumi et al. (2022), que corroboram a eficácia do sensor LiDAR iOS e do aplicativo *ForestScanner* como ferramenta inovadora para inventários florestais. Os autores enfatizam a utilidade e a eficiência desta tecnologia na coleta de dados dendrométricos, contribuindo assim para aprimorar a abordagem geral de inventários florestais.

Por fim, os resultados encontrados nesse estudo e na literatura recente demonstram o potencial de uso de equipamentos iOS com LiDAR, como o aplicativo *ForestScanner* e *CloudCompare*, que não apenas simplifica os procedimentos de coleta de dados, mas também oferece uma abordagem confiável para monitoramento e gestão florestal. O LiDAR nos sistemas sistemas IOS em dispositivos

móveis são mais baratos em relação aos sensores profissionais, e tendem a ser utilizados por outros fabricantes de dispositivos móveis, aumentando a oferta destes dispositivos no mercado e facilitando o acesso para trabalhos de inventário florestal.

CONCLUSÃO

A análise dos resultados da coleta de dados revelou semelhanças entre as medições de DAP transformado a partir do CAP mensurado com fita métrica e as estimativas de DAP obtidas através do sensor LiDAR iOS iPhone 14 Pro, com o aplicativo *ForestScanner* e processamento de dados com *CloudCompare*, evidenciados pelo teste t e análise de correlação. Os principais desafios encontrados incluíram imprecisões na representação tridimensional devido à presença de sub-bosque, bem como a forma de caminhamento, distanciando o sensor das árvores alvo, além do superaquecimento do *smartphone*, ocasionado pelo tamanho do arquivo gerado, tornando o processo mais lento. A metodologia empregada possibilitou visualizar a viabilidade dessa tecnologia para a mensuração florestal. Neste estudo ressalta-se a importância da constante evolução na transformação das práticas tradicionais de mensuração florestal, indicando que a integração de sensores LiDAR em dispositivos iOS, mesmo não sendo um sensor profissional, representa uma tendência promissora e de baixo custo, apesar dos desafios iniciais identificados. Desta forma, é possível o uso desta tecnologia para trabalhos de mensuração e inventário florestal.

REFERÊNCIAS

BALTSAVIAS, E. P. **A comparison between photogrammetry and laser scanning. ISPRS Journal of Photogrammetry and Remote Sensing,** [s. l], v. 54, n. 2/3, p. 83-94, 1999.

BROWN, S.; NARINE, L. L.; GILBERT, J.. Using airborne lidar, multispectral imagery, and field inventory data to estimate basal area, volume, and aboveground biomass in heterogeneous mixed species forests: A case study in southern Alabama. **Remote Sensing**, v. 14, n. 11, p. 2708, 2022.

DALLA CORTE, A. P. et al. Measuring individual tree diameter and height using GatorEye High-Density UAV-Lidar in an integrated crop-livestock-forest system. **Remote Sensing**, v. 12, n. 5, p. 863, 2020.

GOLLOB, C.; RITTER, T.; KRAßNITZER, R.; TOCKNER, A.; NOTHDURFT, A. **Measurement of Forest Inventory Parameters with Apple iPad Pro and Integrated LiDAR Technology**. Remote Sens. 2021, 13, 3129.

INDIRABAI, I. et al. Direct estimation of leaf area index of tropical forests using LiDAR point cloud. **Remote Sensing Applications: Society and Environment**, v. 18, p. 100295, 2020.

KU?ELKA, K.; MARU?ÁK, R.; SUROVÝ, P. Inventory of close-to-nature forest stands using terrestrial mobile laser scanning. **International Journal of Applied Earth Observation and Geoinformation**, 115, 2022. Doi: 10.1016/j.jag.2022.103104

MURTIYOSO, A.; GRUSSENMEYER, P.; LANDES, T.; MACHER, H**. First assessments into the use of commercial-grade solid state lidar for low cost heritage documentation**. Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci. 2021, XLIII-B2-2, 599-604.

PERUGIA, B. D.; GIANNETTI, F.; CHIRICI, G.; TRAVAGLINI, D. Influence of scan density on the estimation of single-tree attributes by hand-held mobile laser scanning. **Forests**, v. 10, n. 3, p. 277, 2019. Doi: 10.3390/f10030277

SOARES, C. P. B.; PAULA NETO, F.; SOUZA, A. L.; **Dendrometria e inventário florestal.** Viçosa, MG. 2º Ed. Editora UFV, 2011. 272 p.

TATSUMI, S.; YAMAGUCHI, K.; FURUYA, N. **ForestScanner: A mobile application for measuring and mapping trees with LiDAR equipped iPhone and iPad**. Methods in Ecology and Evolution, p. 1603 - 1609, 2022.

VOGT, M.; RIPS, A.; EMMELMANN, C. **Comparison of iPad Pro®'s LiDAR and TrueDepth Capabilities with an Industrial 3D Scanning Solution**. Technologies 2021, 9, 25.

OTIMIZAÇÃO DO MÉTODO DE ANÁLISE DE SOLO VIA XRF: AVALIAÇÃO DE CENÁRIOS COM DIFERENTES TEMPOS DE ANÁLISE E REPLICATAS

GABRIEL VILLELA BEDUM [1]; MATEUS SILVA GELAIN [1]; TIAGO RODRIGUES TAVARES [2]; HUDSON WALLACE PEREIRA DE CARVALHO [3]; JOSÉ PAULO MOLIN [4]

[1]Graduando. Piracicaba-SP. Escola Superior de Agricultura 'Luiz de Queiroz; [2]Pesquisador Pós-Doc. Piracicaba-SP. Laboratório de Instrumentação Nuclear (CENA); [3]Professor. Benguerir, Marrocos. University Mohammed VI Polytechnic; [4]Professor titular. Piracicaba-SP. Escola Superior de Agricultura 'Luiz de Queiroz

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

O presente estudo busca sugerir um cenário de tempo de escaneamento e número ótimo de repetição de uma mesma amostra, ou replicatas, para analisar amostras de solo com sensor de fluorescência de raios X (XRF) em ambiente de laboratório. Mais especificamente, avaliaram-se os cenários de 30 s e 1 replicata (30s+1r), 15 s e 2 replicatas (15s+2r), 10 s e 3 replicatas (10s+3r) e 6 s e 5 replicatas (6s+5r), todos mantendo o tempo total de análise em 30 s para a predição dos teores de argila e nutrientes extraíveis (ex-Ca e ex-K) em solos tropicais. Para isso, a pesquisa utilizou 58 amostras de solo provenientes de três áreas agrícolas distintas e calibrou modelos de regressão linear múltipla (RLM) para predição dos teores de argila, ex-Ca e ex-K em cada um dos cenários. Os resultados mostraram que modelos de RLM para argila (R2 = 0,97) e ex-Ca (R2 = 0,55) apresentaram desempenho satisfatório (RPIQ ≥ 1,7) para os cenários 30s+1r, 15s+2r e 10s+3r. Enquanto, para a variável ex-K (R2 = 0,67) a performance foi ruim (RPIQ < 1,4) em todos os cenários. Os cenários 30s+1r, 15s+2r e 10s+3r apresentaram resultados estatisticamente semelhantes, apesar disso, é sugerido o uso de 10s+3r predição de atributos de fertilidade do solo utilizando sensor XRF, uma vez que maximiza o número de replicatas sem perder desempenho analítico em função da redução do tempo. Isso permite lidar melhor com amostras heterogêneas e com a micro heterogeneidade na distribuição do analito na amostra de solo.

PALAVRAS-CHAVE: Modelagem preditiva; diagnóstico de fertilidade; sensoriamento proximal

ABSTRACT

The present study seeks to propose a scanning time scenario and an optimal number of repetitions of the same sample, or replicates, to analyze soil samples with an X-ray fluorescence (XRF) sensor in a laboratory environment. More specifically, the scenarios of 30 s and 1 replicate (30s+1r), 15 s and 2 replicates (15s+2r), 10 s and 3 replicates (10s+3r) and 6 s and 5 replicates (6s+5r) were evaluated, all keeping the total analysis time at 30 s to predict the contents of clay and extractable nutrients (ex-Ca and ex-K) in tropical soils. For this, the research used 58 soil samples from three different agricultural areas and calibrated multiple linear regression models (RLM) to predict clay, ex-Ca and ex-K contents in each of the scenarios. The results showed that RLM models for clay (R2 = 0.97) and ex-Ca (R2 = 0.55) presented superior performance (RPIQ ≥ 1.7) for the 30s+1r, 15s+2r and 10s+ 3r scenarios. While, for the ex-K variable (R2 = 0.67) the performance was poor (RPIQ < 1.4) in all scenarios. The 30s+1r, 15s+2r and 10s+3r scenarios presented statistically similar results, despite this, it is suggested to use 10s+3r for prediction of soil fertility attributes using an XRF sensor, as it maximizes the number of replicates without losing analytical performance due to time reduction. This allows you to better deal with heterogeneous samples and micro heterogeneity in the distribution of the analyte in the soil sample.

KEYWORDS: ;

INTRODUÇÃO

O sensoriamento do solo permite monitoramento de variáveis agrícolas em escala espacial e temporal compatível com as abordagens da agricultura de precisão (AP) (MOLIN e TAVARES, 2019). Para tanto, o tempo de análise mínimo necessário para que sensores possam obter um sinal analítico preciso é um fator fundamental para entender a compatibilidade de cada técnica com aplicações dentro do contexto da AP, seja *in situ* ou laboratorialmente. O tempo de análise determina o rendimento operacional de um sensor, que representa o número de amostras que conseguirá analisar por unidade de tempo e que é função do tempo de escaneamento e o número de replicatas que são realizadas para cada amostra. Em relação às técnicas de sensoriamento próximo do solo, uma abordagem relativamente consolidada na AP é a espectroscopia de reflectância difusa, a qual utiliza as faixas do visível e infravermelho próximo (vis-NIR) para gerar a informação sobre atributos de solo e planta (JAVADI et al., 2021; MOLIN e TAVARES, 2019; XU et al., 2019). Mais recentemente, há uma expansão de abordagens e aplicações de sensores de fluorescência de raios X (XRF) na AP e pedometria (SILVA et al., 2021). Sensores vis-NIR permitem a realização de leituras praticamente instantâneas, e.g., escaneando o alvo uma vez a cada segundo. Por outro lado, usuários de sensores XRF usualmente utilizam tempos de análise entre 30 e 90s para avaliação de amostras de solo em laboratório, o que destoa das análises instantâneas empregadas por equipamentos vis-NIR. Apesar disso, têm-se observado que equipamentos XRF permitem a caracterização de solo de forma complementar aos dados obtidos por vis-NIR (JAVADI et al., 2021), trazendo informações dos elementos químicos presentes nas amostras (ANDRADE et al., 2020). Frente a este impasse no tempo de análise do XRF, um estudo recente mostrou a possibilidade de se reduzir drasticamente o tempo de análise de solo com o XRF (de 90 para 2 s) mantendo desempenhos analíticos satisfatórios [razão de desempenho para distância interquartil (RPIQ) superior a 2] (TAVARES et al., 2023). Embora aplicações em laboratório não careçam de tempo tão reduzido como aplicações *in situ* (e.g., 2 s), o trabalho TAVARES et al., (2023) demonstrou a possibilidade de se otimizar o tempo que atualmente oscila entre 60 e 90 s. Uma vantagem de reduzir o tempo de análise seria a possibilidade de incrementar o número de replicatas. Neste contexto, surge a seguinte questão que motivou a condução desse trabalho: "Como comportaria o desempenho preditivo de modelos com dados XRF ao reduzir o tempo de análise e aumentar o número de replicatas?".

OBJETIVOS

Para este trabalho, objetivou-se avaliar diferentes cenários de tempos de análise e replicatas, pensando em manter a duração total de análise da amostra em 30s, o que é compatível com aquisição de dados espectrais em laboratórios. Mais especificamente, foram analisados os cenários de 30s com 1 replicata (30s+1r), 15s com 2 replicatas (15s+2r), 10s com 3 replicatas (10s+3r) e 6s com 5 replicatas (6s+5r) para a predição dos teores de argila, ex-Ca e ex-K em amostras provenientes de três áreas agrícolas diferentes.

MATERIAL E MÉTODOS

Foram utilizadas 58 amostras de solo, oriundas de três áreas agrícolas de diferentes municípios do Estado de São Paulo, são eles, Monte Azul, Patrocínio Paulista e Coronel Macedo. As amostras foram enviadas para um laboratório comercial, onde foram submetidas às análises de rotina de fertilidade do solo para determinação de seus teores de argila e os nutrientes extraíveis ex-K e ex-Ca. As determinações de argila foram feitas utilizando o método da pipeta e dos nutrientes via extração usando NH4Cl 1 mol L-1 e quantificação por espectrometria de emissão óptica com plasma indutivamente acoplado (ICP-OES). Os espectros das amostras foram obtidos usando um XRF portátil (Tracer III-SD, Bruker AXS, Madison, WI, EUA). O tubo de raios X foi configurado a uma tensão de 35 kV e corrente de 7 uA. As leituras foram feitas sob pressão atmosférica (ou seja, sem utilização de vácuo) e sem filtro primário. As cubetas foram preparadas com filme de polipropileno

de 4 μm de espessura (SPEX, Metuchen, NJ, EUA) e preenchidas com 10 g de amostra. O uso de replicatas, ou seja, o número de leituras com o sensor que são realizadas em uma mesma amostra, é uma forma de explorar a variabilidade interna dela (BELON-MOUREL et al., 2010). Assim, todas as amostras foram escaneadas com o XRF utilizando 4 diferentes cenários de tempo e replicata, são eles: 30s+1r, 15s+2r, 10s+3r e 6s+5r. Em todos os cenários, descontando o tempo gasto para mover a amostra entre cada replicata, o tempo total de análise foi de 30 s, o que é compatível com análises conduzidas em laboratório. Foram utilizados o espectro médio das replicatas para as modelagens. Para tal, as amostras foram divididas em dois conjuntos, um de calibração, contendo 70% dos dados (n = 41), e outro de validação, contendo o restante, 30% (n = 17) das amostras. A divisão foi realizada de modo que o conjunto de calibração apresentasse maior amplitude e desvio padrão semelhante ao conjunto de validação. A modelagem de dados foi realizada com o programa Unscrambler (Camo AS, Oslo, Noruega). Os modelos de regressão linear múltipla (RLM) para predição de argila foram calibrados com as linhas de emissão do alumínio, titânio e ferro, conhecidas como Al-Kα, Ti-Kα e Fe-Kα, respectivamente. Os modelos de ex-Ca utilizaram as linhas de emissão do alumínio, ferro e cálcio (Ca-Kα), por sua vez, os modelos de ex-K foram calibrados com as linhas de emissão do alumínio, ferro e potássio (K-Kα). Essas linhas de emissão foram escolhidas, pois corriqueiramente são as variáveis mais importantes para predição de cada um desses atributos, como nos trabalhos já realizados em solos tropicais brasileiros (ANDRADE et al., 2020; LIMA et al., 2019; TAVARES et al., 2020). O fluxograma da metodologia empregada está esquematizado na Figura 1.

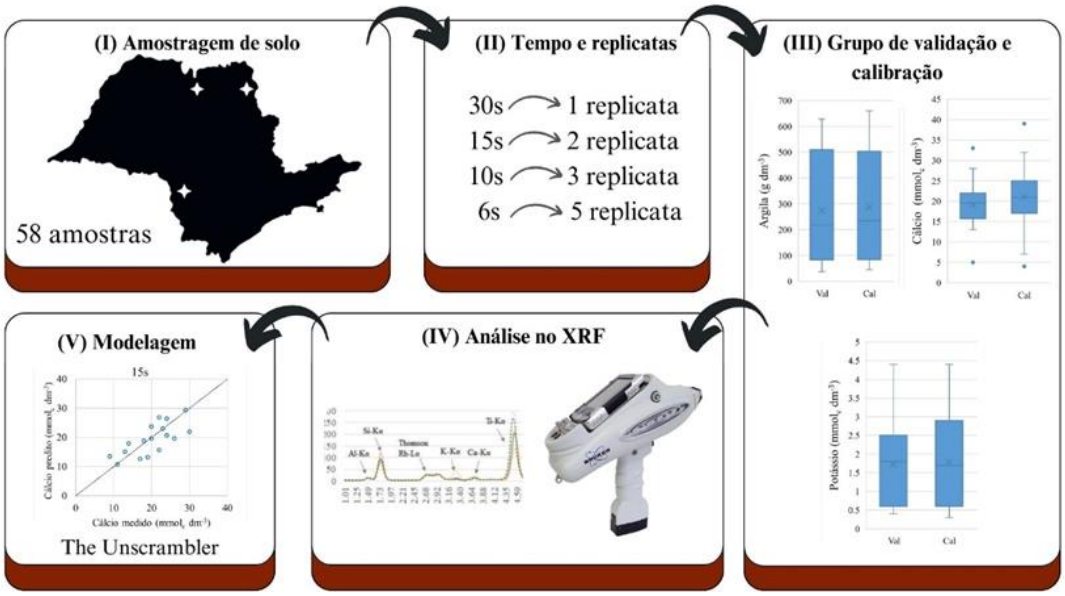


FIGURA 1. Fluxograma da metodologia aplicada para avaliar o efeito dos cenários de análise com redução do tempo de leitura e aumento do número de replicatas em análises realizadas com sensor de fluorescência de raios X (XRF) para predição de argila, ex-Ca e ex-K. **Flowchart of the methodology applied to evaluate the effect of analysis scenarios with reduced reading time and increased number of replicates in analyzes carried out with an X-ray fluorescence (XRF) sensor to predict clay, ex-Ca and ex-K.**

A qualidade dos modelos foi comparada tomando como base o coeficiente de determinação (R^2), a razão de desempenho para distância interquartil (RPIQ), o desvio sistemático do valor real (BIAS) e a raiz do erro quadrático médio (RMSE) (BELON-MOUREL et al., 2010). A interpretação do RPIQ foi fundamentada nas classes apresentadas na Tabela 1. Por fim, os valores de RMSE de cada cenário foram comparados estatisticamente via teste Tukey.

TABELA 1. Classes de RPIQ utilizada para a avaliação da performance de modelos preditivos. **RPIQ classes used to evaluate the performance of predictive models.**

Performance:	Excelente	Muito Bom	Bom	Falho	Ruim
	RPIQ ≥ 2,5	2,5 > RPIQ ≥ 2,0	2,0 > RPIQ ≥ 1,7	1,7 > RPIQ ≥ 1,4	1,4 > RPIQ

RESULTADOS E DISCUSSÃO

A estatística descritiva dos conjuntos de calibração e validação estão apresentadas na Tabela 2, a qual ambos os conjuntos apresentam métricas de dispersão semelhantes. O conjunto da calibração é sempre mais abrangente que o de validação, de modo a evitar que as predições sejam feitas em um conjunto de validação com intervalos fora daquele utilizado para construção do modelo. Essa estratégia tem como finalidade evitar potenciais impactos negativos no desempenho dos modelos, os quais poderiam estar associados à disparidade na amplitude dos valores dos conjuntos, e não necessariamente à eficácia dos sensores XRF (STENBERG et al., 2010).

TABELA 2. Estatística descritiva dos atributos químicos do solo para o conjunto de calibração e validação. **Descriptive statistics of soil chemical attributes for the calibration and validation set.**

	Argila	ex-Ca	ex-K
	g dm-3	----- $mmol_c\ dm^{-3}$ -----	
	-------- Conjunto de calibração (n=41) --------		
Mínimo	37,00	5,00	0,30
Máximo	643,00	32,00	4,30
Média	144,08	19,33	1,05
1° Quartil	68,25	16,25	0,50
3° Quartil	136,00	23,00	0,80
DP	134,00	5,79	0,90
CV	93,08	29,94	85,66
	-------- Conjunto de validação (n=17) --------		
Mínimo	43,00	9,00	0,40
Máximo	537,00	30,00	3,60
Média	137,77	20,06	1,05
1° Quartil	58,00	17,00	0,50
3° Quartil	125,00	24,00	1,00
DP	136,03	5,95	0,98
CV	98,74	29,68	93,00

O desempenho dos diferentes cenários de análise avaliados neste trabalho é apresentado na Tabela 3. De maneira geral, obtiveram predições satisfatórias (RPIQ ≥ 1,7) em sua validação os modelos preditivos de argila e ex-Ca. Por outro lado, modelos preditivos de ex-K mostraram-se sempre com

desempenho fraco (RPIQ ≤ 0,84). Os gráficos de dispersão que correlacionam os valores de referência dos atributos de fertilidade com os preditos pelos modelos RLM são apresentados na Figura 2. Verifica-se que, para o modelo de argila, os ensaios com 30s, 15s e 10s apresentaram dispersão de pontos com um comportamento linear, posicionado próximo à reta 1:1, o que corrobora com desempenhos excelentes reportados na Tabela 3. Por sua vez, ao analisar os scatter plots do ex-Ca, nota-se que os pontos seguem a linha de tendência 1:1, porém com um comportamento mais disperso. Ao estudar o conjunto gráfico referente ao ex-K, constata-se uma maior dispersão dos pontos, o que reflete nos modelos com desempenhos fracos. Os resultados observados corroboram com o reportado na literatura avaliando solos tropicais. Por exemplo, Lima et al. (2019) observaram predições com desempenho alto ($R^2 = 0,85$) para o diagnóstico de argila. Andrade et al. (2020) mostrou desempenhos preditivos com R^2 de 0,71 para ex-Ca e de 0,67 para ex-K. Por sua vez, o desempenho para a predição de ex-K apresenta-se mais variáveis, com desempenhos bons (R2 > 0,80) (TAVARES et al., 2020) e, em alguns casos, com desempenho ruim (R2 < 0,12) (TEIXEIRA et al., 2018). Em solos tropicais, a predição satisfatória de ex-K e ex-Ca é justificada pela mineralogia predominantemente de óxidos e caulinita, ou seja, pobre em minerais com presença de Ca e K em sua estrutura (TAVARES et al., 2023). No presente trabalho, predições ruins foram obtidas para ex-K, provavelmente devido à presença de solos com mica ou feldspato (i.e., fontes naturais de K) em algumas das amostras, o que incrementa a complexidade nas relações entre teores totais e disponíveis e pode minar o desempenho preditivo desses atributos.

TABELA 3. Desempenho obtido nos conjuntos de calibração e validação para predição de argila, ex-Ca e ex-K para os diferentes cenários de tempo de análise e replicatas avaliados neste trabalho. Os gráficos de dispersão das predições do conjunto de validação são apresentados na Figura 2. Os valores de RMSE dos conjuntos de validação foram comparados por teste Tukey e letras diferentes indicam diferença significativa com P < 0,01. **Performance obtained in the calibration and validation sets for predicting clay, ex-Ca and ex-K for the different analysis time scenarios and replicates evaluated in this work. The scatterplots of the validation set predictions are presented in Figure 2. The RMSE values of the validation sets were compared using the Tukey test and different letters indicate a significant difference with P < 0,01.**

	Argila							
	30s+1r		**15s+2r**		**10s+3r**		**6s+5r**	
	Cal	Val	Cal	Val	Cal	Val	Cal	Val
R^2	0,86	0,96	0,88	0,96	0,89	0,97	0,22	0,56
RPIQ	2,33	3,04	2,54	3,10	2,57	3,34	0,92	0,90
Bias	-2,30	-3,30	-2,13	-3,32	-2,06	-3,96	1,07	12,86
RMSE	47,44	27,47 (b)	43,43	26,92 (b)	42,93	24,98 (b)	120,27	93,13 (a)
	Ex-Ca							
	30s+1r		**15s+2r**		**10s+3r**		**6s+5r**	
	Cal	Val	Cal	Val	Cal	Val	Cal	Val
R^2	0,61	0,61	0,59	0,53	0,56	0,55	0,15	0,29
RPIQ	1,96	2,16	1,89	2,04	1,84	2,09	1,27	1,63

Bias	0,06	-0,77	0,06	-0,74	0,09	-0,68	0,23	1,53
RMSE	3,58	3,94 (a)	3,70	4,17 (a)	3,80	4,06 (a)	5,51	5,22 (a)
				Ex-K				
	30s+1r		**15s+2r**		**10s+3r**		**6s+5r**	
	Cal	Val	Cal	Val	Cal	Val	Cal	Val
R^2	0,57	0,66	0,50	0,67	0,59	0,67	0,22	0,28
RPIQ	1,37	0,80	1,27	0,84	1,40	0,81	0,99	0,62
Bias	0,01	-0,19	0,02	-0,16	0,01	-0,20	0,03	0,02
RMSE	0,73	0,63 (a)	0,79	0,59 (a)	0,71	0,62 (a)	1,01	0,81 (a)

Observa-se que as predições de argila e ex-Ca com os cenários 30s+1r, 15s+2r e 10s+3r apresentaram desempenho excelente para argila (RPIQ > 3,0) e muito bom para ex-Ca (RPIQ > 2,0). Por sua vez, o cenário 6s+5r mostrou desempenho ruim (RPIQ < 1,4) para todos os atributos avaliados. A redução do desempenho ao reduzir o tempo para 6 s ocorre, pois o desvio padrão dos espectros XRF aumenta de forma exponencial à redução do tempo de análise (MONDIA et al., 2015). Ou seja, espectros obtidos com tempos de análise mais curtos têm um maior ruído que espectros obtidos com maior tempo de permanência. Tavares et al. (2023) ao utilizar um equipamento semelhante ao deste trabalho observaram incrementos do desvio padrão estáveis até tempos de análise de 10 s e, ao continuar reduzindo o tempo de análise para 7, 4 e 2 s, incrementos crescentes do desvio padrão dos dados (i.e., perda de precisão) foram observados. No presente trabalho, embora o cenário com 10s+3r não tenha diferido estatisticamente dos cenários de 30s+1r e de 15s+2r, ele apresentou o menor erro para predição de argila e o segundo menor erro para a predição de ex-Ca e ex-K. Além disso, é um cenário que maximiza o número de replicatas, o que permite uma melhor caracterização de amostras da micro-heterogeneidade usualmente presente em amostras solo (TAVARES et al., 2019). Também é importante comentar que aumentar o número de replicatas em análises espectrais pode ser uma alternativa para identificar amostras com contaminação, e.g., amostras de subsuperfícies contaminadas com amostras de superfície, e removê-las da calibração de modelos preditivos. Os resultados observados no presente trabalho, bem como o ganho analítico de se aumentar o número de replicatas, permitem sugerir o cenário de 10s+3r para a calibração e validação de modelos preditivos de atributos de solo utilizando sensores XRF em bancada. Comenta-se ainda que, à medida que tecnologias de fonte de raios X e detectores forem sendo aprimoradas, cenários com tempo de análise mais reduzidos devem ser avaliados. Por fim, mencionamos que otimizações do tempo de análise e replicatas são fundamentais para o planejamento do processo de automação da análise com sensores em laboratórios, bem como para entender o rendimento operacional de análises. Considerando o cenário 10s+3r, podemos estimar um tempo de análise total de 37s por amostra, ou seja, 30s de tempo de análise, acrescido do tempo para alterar a posição entre replicatas (± 2s) e entre amostra (±5s). Esse tempo total de análise por amostra permitiria um rendimento de aproximadamente 97 amostras por hora.

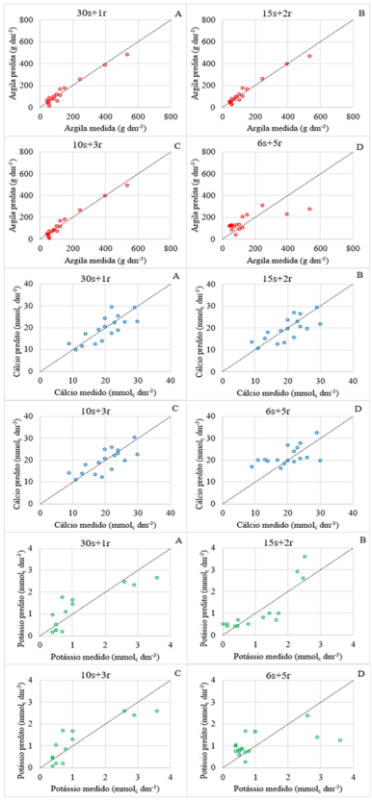


FIGURA 2. Dispersão do conjunto de validação para as predições de argila (vermelho), ex-Ca (azul) e ex-K (verde) em cada um dos quatro cenários de tempo de análise e replicatas avaliados neste estudo. **Dispersion of the validation set for clay (red), ex-Ca (blue) and ex-K (green) predictions in each of the four analysis time scenarios and replicates evaluated in this study.**

CONCLUSÃO

De modo geral, obtiveram-se modelos com desempenho satisfatório para a predição de argila e ex-Ca, enquanto o ex-K apresentou performance inferior. Em relação aos quatro cenários de tempo de análise e replicatas avaliados, o cenário 6s+5r apresentou desempenhos preditivos ruins, com RPIQ menor que 1,63 para a predição de todos os atributos avaliados. Por outro lado, desempenhos estatisticamente semelhantes foram obtidos com todos os outros cenários com RPIQ oscilando entre 3,04 e 3,34 para argila, variando entre 2,04 e 2,16 para ex-Ca e entre 0,80 e 0,84 para ex-K. Recomenda-se utilizar o cenário 10s+3r para análise de solo em bancada via XRF, uma vez que o tempo de análise de 10 s permite construir modelos robustos e ainda maximiza o número de replicatas, o que propicia uma melhor caracterização da micro-heterogeneidade da amostra.

AGRADECIMENTOS

Agradecemos à empresa Ribersolo Laboratório de Análises Agrícolas, pela disponibilização das amostras e análises de referência.

REFERÊNCIAS

ANDRADE, R. FARIA, W.M.; SILVA, S.H.G. CHAKRABORTY, S.; WEINDORF, D.C.; MESQUITA, L.F. GUILHERME, L.R.G. CURI, N. Prediction of soil fertility via portable x-ray fluorescence (pxrf) spectrometry and soil texture in the brazilian coastal plains. **Geoderma**, 357, p.113960, 2020.

BELLON-MAUREL, V.; FERNANDEZ-AHUMADA, E.; PALAGOS, B.; ROGER, J.M. MCBRATNEY, A. Critical review of chemometric indicators commonly used for assessing the quality of the prediction of soil attributes by NIR spectroscopy. **TrAC Trends in Analytical Chemistry**, v.29, n.9, p.1073-1081, 2010.

JAVADI, S. H.; MUNNAF, M. A.; MOUAZEN, A. M. Fusion of Vis-NIR and XRF spectra for estimation of key soil attributes. **Geoderma**, v. 385, p. 114851, 2021.

KRUG, F. J.; ROCHA, F. R. P. Métodos de preparo de amostras para análise elementar. **EditSBQ, Sociedade Brasileira de Química, São Paulo, 572p**, 2016.

LIMA, T.M.; WEINDORF, D.C.; CURI, N.; GUILHERME, L.R.; LANA, R.M.; RIBEIRO, B.T. Elemental analysis of Cerrado Agricultural soils via portable X-ray fluorescence spectrometry: Inferences for soil fertility assessment. **Geoderma**, v.353, p.264-272, 2019.

MOLIN, J. P.; TAVARES, T. R. Sensor systems for mapping soil fertility attributes: challenges, advances, and perspectives in brazilian tropical soils. **Engenharia Agrícola,** v. 39, p. 126-147, 2019.

MONDIA, J.P., GOH, F., BRYNGELSON, P.A., MACPHEE, J.M., ALI, A.S., WEISKOPF, A. AND LANAN, M. Using X-ray fluorescence to measure inorganics in biopharmaceutical raw materials. **Analytical Methods**, 7(8), p. 3545-3550, 2015.

SILVA, S.H.G.; RIBEIRO, B.T.; GUERRA, M.B.B.; CARVALHO, H.W.P.; LOPES, G.; CARVALHO, G.S.; GUILHERME, L.R.G.; RESENDE, M.; MANCINI, M.; CURI, N. RAFAEL, R.B.A. pXRF in tropical soils: Methodology, applications, achievements and challenges. **Advances in Agronomy**, v. 167, p.1-62, 2021.

STENBERG, B.; VISCARRA ROSSEL, R.A.; MOUAZEN, A.M.; WETTERLIND, J. Visible and near infrared spectroscopy in soil science. **Advances in Agronomy**, v.107, p.163-215, 2010.

TAVARES, T.R., MINASNY, B., MCBRATNEY, A., CHERUBIN, M.R., MARQUES, G.T., RAGAGNIN, M.M., ALVES, E.E.N., PADARIAN, J., LAVRES, J. AND DE CARVALHO, H.W.P. Estimating plant-available nutrients with XRF sensors: Towards a versatile analysis tool for soil condition assessment. **Geoderma**, 439, p. 116701, 2023.

TAVARES, T. R.; MOLIN, J. P.; ALVES, E. E. N.; MELQUIADES, F. L.; CARVALHO, H. W. P. de; MOUAZEN, A. M. Towards rapid analysis with XRF sensor for assessing soil fertility attributes: Effects of dwell time reduction. **Soil and Tillage Research**, v. 232, p. 105768, 1 ago. 2023.

TAVARES, T. R.; MOLIN, J.P.; NUNES, L.C.; ALVES, E.E.N.; MELQUIADES, F.L.; CARVALHO, H.W.P.; MOUAZEN, A.M. effect of X-ray tube configuration on measurement of key soil fertility attributes with XRF. **Remote Sensing**, v.12, n.6, p.963, 2020.

TAVARES, T. R.; NUNES, L. C.; ALVES, E. E. N.; ALMEIDA, E. de; MALDANER, L. F.; KRUG, F. J.; CARVALHO, H. W. P. de; MOLIN, J. P. Simplifying Sample Preparation for Soil Fertility Analysis by X-ray Fluorescence Spectrometry. **Sensors**, v. 19, n. 23, 2019.

TEIXEIRA, A.F.D.S.; WEINDORF, D.C.; SILVA, S.H.G.; GUILHERME, L.R.G.; CURI, N. Portable X-ray fluorescence(pXRF) spectrometry applied to the prediction of chemical attributes in Inceptisols under different land uses. **Ciênc. Agrotec**, v.42, p.501-512,2018.

VAN RAIJ, B.; ANDRADE, J.C.; CANTARELLA, H.; QUAGGIO, J.A. Análise química para avaliação de solos tropicais. **IAC**: Campinas, Brasil, p.285,2001.

XU, D.; ZHAO, R.; LI, S. CHEN, S.; JIANG, Q.; ZHOU, L.; SHI, Z. Multi-sensor fusion for the determination of several soil properties in the Yangtze River Delta, China. **European Journal of Soil Science**, v. 70, n. 1, p. 162-173, 2019.

MAPEamento de produtividade de cana-de-açúcar por meio de sensor volumétrico

Julio César Masnello [1]; Filipe de Oliveira Moreira [1]; Ricardo Canal Filho [2]; Eudocio Rafael Otavio da Silva [2]; José Paulo Molin [3]

[1]Graduando. Piracicaba - SP, Brasil. Laboratório de Agricultura de Precisão, Departamento de Engenharia de Biossistemas, Escola Superior de Agricultura 'Luiz de Queiroz; [2]Doutorando. Piracicaba - SP, Brasil. Laboratório de Agricultura de Precisão, Departamento de Engenharia de Biossistemas, Escola Superior de Agricultura 'Luiz de Queiroz; [3]Professor Titular. Piracicaba - SP, Brasil. Laboratório de Agricultura de Precisão, Departamento de Engenharia de Biossistemas, Escola Superior de Agricultura 'Luiz de Queiroz

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

São poucas as alternativas disponíveis ao setor canavieiro para monitoramento da produtividade das lavouras. Nos últimos anos, entretanto, a pesquisa tem se dedicado a desenvolver métodos, que vão desde a estimativa a partir de parâmetros do motor, até o uso de sensores e inteligência artificial. O presente trabalho objetiva analisar dados de obtidos com um monitoramento da produtividade que utiliza um sensor óptico volumétrico, e está recentemente sendo introduzida ao mercado brasileiro. Os dados (95.206 pontos) foram gerados durante a colheita de uma área de 16,00 ha, submetidos ao um processo de filtragem, restando em 55.742 pontos a serem analisados numa abordagem exploratória, estatística e agronômica, com foco na orientação à tomada de decisão. Dois métodos de aplicação a esses dados são apresentados, para averiguar sua efetividade em mapear a produtividade, em vista principalmente da alta densidade de coleta de dados do sistema (1 Hz) associada à alta precisão de posicionamento (± 3,50 cm). A tecnologia apresenta alto potencial para uso na agricultura de precisão e futuros trabalhos com esse monitor podem testar seu uso para recomendação de fertilizantes em taxas variadas, identificação de falhas, entre diversas aplicações possíveis.

PALAVRAS-CHAVE: Dados; Precisão; Sustentabilidade

ABSTRACT

Few alternatives are available to the sugarcane sector for monitoring crop productivity. However, in recent years, research has been dedicated to developing methods ranging from estimation based on engine parameters to the use of sensors and artificial intelligence. This study aims to present a new tool for monitoring productivity applied to sugarcane cultivation, which utilizes a volumetric optical sensor, in contrast to other methods already used for this measurement, and is recently being introduced to the market. The monitoring system is presented based on a database generated during the harvest of a 16.00 ha area. The data provided by the monitor were filtered, leaving a high volume (55,742 points) yet to be analyzed. An exploratory, statistical, and agronomic analysis followed to explore the functionalities that the new technology can offer decision-making. Two methods of application to these data are presented to assess their effectiveness in mapping productivity, primarily considering the high data collection density of the system (1 Hz) associated with high positioning accuracy (± 3.50 cm). The technology demonstrates high potential for use in precision agriculture. Future work with this monitor may test its use for recommending fertilizers at varied rates, identifying faults, among various possible applications.

KEYWORDS: ;

INTRODUÇÃO

A agricultura brasileira, um dos principais setores econômicos nacionais, vêm buscando sempre seu aperfeiçoamento e tecnificação, a fim de aumentar sua produção sem necessitar da expansão territorial, respeitando a demanda contemporânea por sustentabilidade (SMITH et al., 2016; SCHLEIFER, 2017). Para isso, a agricultura de precisão (AP) focaliza na otimização de recursos e no aproveitamento máximo lucrativo e sustentável das lavouras, sendo essencial nos estudos da variabilidade espacial presente no campo. Considerando essa variabilidade espacial, consegue-se realizar manejos mais eficientes e acurados, evitando subdosagens ou o desperdício com sobredoses e em busca de um manejo econômico e ambientalmente sustentável. Os mapas de produtividade, que sintetizam a resposta da cultura no campo, representam camadas de informação fundamental para essa abordagem. (MOLIN, 2002).

O setor canavieiro, apesar de sua importância global na segurança alimentar e transição energética sustentável (BORDONAL et al., 2018; CHERUBIN et al., 2021), enfrenta desafios devido à escassez de soluções adequadas para mapear a produtividade das lavouras (MOLIN et al., 2024). As primeiras soluções começaram a ser desenvolvidas no final dos anos 1990 e início da década de 2000, com sensores de pressão do picador e potência do elevador (COX & COX, 1998) e com sensores de fluxo de massa (BENJAMIM et al., 2001; MAGALHÃES & CERRI, 2007). Com baixa adesão e nenhuma alternativa comercial, anos mais tarde alternativas foram propostas, com a obtenção de dados indiretamente a partir de parâmetros do motor (MALDANER et al., 2021), até utilizando a fusão de sensores dedicados e redes neurais (LIMA et al., 2021). Uma alternativa comercial recente, gera dados da produção de forma indireta, a partir de variações na pressão hidráulica no sistema picador de colmos da colhedora (MALDANER et al., 2022). Fato é que, com poucas opções disponíveis, e sendo muito recentes, a adoção dos mapas de produtividade ainda é baixa na produção de cana-de-açúcar (CARRER et al., 2022).

Recentemente, uma nova tecnologia de monitoramento da produtividade está disponível para a cana-de-açúcar. Utilizando câmeras 3D como sensores ópticos, o sistema monitora o volume de material que passa sobre a esteira elevadora, estimando de forma direta a produção. Integrado a unidades de georreferenciamento, é um sistema comercial que permite o monitoramento da produtividade em tempo real. Entretanto, ainda não há, disponíveis na literatura, trabalhos que explorem essa tecnologia.

OBJETIVOS

Neste sentido, o presente trabalho tem como objetivo apresentar essa nova ferramenta, a partir de um conjunto de dados da colheita de uma lavoura comercial que utilizou este sistema de monitoramento da produtividade embarcado na colhedora, e verificar os apontamentos que se tornam possíveis a gestão agrícola a partir dos dados disponibilizados pelo sistema.

MATERIAL E MÉTODOS

Os dados foram coletados em uma lavoura comercial de aproximadamente 16,00 ha, localizada no município de Buritizal, região noroeste do estado de São Paulo. A lavoura foi implantada no espaçamento de 1,50 m em maio de 2021, com a primeira colheita ocorrendo em maio de 2022. Para o presente estudo, foram utilizados os dados da colheita de maio de 2023, tendo a lavoura idade de segundo corte. A colheita foi realizada de forma mecanizada, utilizando uma colhedora de uma linha, modelo CH570 (John Deere, Catalão, GO). Essa colhedora continha embarcado o sistema *Cane Advisor*™, composto pelo *Harvest Monitor*™ e pelo sistema *Smart Clean*™, responsáveis pelo monitoramento da produtividade em tempo real durante a operação de colheita (John Deere, Indaiatuba, SP).

O monitor de produtividade funciona pelo princípio volumétrico, estimando por parâmetros diretos a quantidade de cana-de-açúcar colhida, e fornecendo esses dados em tempo real ao operador. Câmeras digitais 3D são embarcadas na esteira da colhedora para monitorar o volume de cana, palha e outras impurezas, estimando os valores de massa de cana colhida, impurezas e perda de cana (estilhaços). Além disso, o sistema de monitoramento do extrator primário, em conjunto com as informações geradas pelos sensores ópticos embarcados, sugerem a melhor velocidade e rotação dos extratores a fim de minimizar a perda de cana por estilhaços e maximizar a eliminação de impurezas. Dessa forma, toda a colheita foi realizada utilizando os parâmetros sugeridos pelo sistema automático de regulagem da velocidade e rotação dos componentes da colhedora.

O sistema permite a coleta de dados na frequência de 1 Hz, e georreferenciados pelo sistema de navegação global por satélite (GNSS) integrado, utilizando uma antena receptora *StarFire* 6000 (John Deere, Indaiatuba, SP) posicionada no topo da cabine da colhedora, com sinal RTK e precisão de ± 3,50 cm. O sistema armazena, ponto a ponto, os dados de distância e tempo de coleta entre os pontos, data e hora de coleta, largura de corte, velocidade de operação, consumo de combustível, massa de impurezas estimada, massa de cana-de-açúcar estimada, elevação, longitude e latitude. Segundo o fabricante, a calibração do sistema tem como base a totalização de massa de três transbordos, inseridas de forma manual ou via telemetria.

Com base em trabalhos da literatura que exploraram a variabilidade da produção de cana-de-açúcar em sistemas mecanizados, foram utilizados os parâmetros do motor (MALDANER et al., 2022), e de elevação (SANCHES et al., 2020) para as análises exploratórias do presente estudo.

Para análise dos dados foi utilizado o sistema de informação geográfica (SIG) QGIS (QGIS DEVELOPMENT TEAM, 2023), juntamente com o complemento *Smart-Map* (PEREIRA et al., 2022); e para posteriores análises e realização dos gráficos a linguagem de programação *Python* pela interface do programa *Jupyter Notebook* (KLUYVER et al., 2016). A priori, foi realizada uma filtragem dos dados obtidos, focado em dados de produtividade de cana-de-açúcar georreferenciados, com a finalidade de eliminar valores atípicos (*outliers*).

Uma análise de correlação entre o vetor de dados filtrados se seguiu entre a produtividade e outras variáveis geradas pelo sistema: consumo de combustível, massa de impurezas estimada, elevação e velocidade de operação. O objetivo foi verificar possíveis interações relevantes entre os dados. Onde a correlação mostrou maiores valores, seguiu-se uma análise de regressão linear ($p<0,01$), visando validar a significância da relação entre as variáveis.

Os dados foram submetidos a análise geoestatística e os mapas foram interpolados por krigagem ordinária, método eficaz para inferência de valores em variáveis agronômicas (DALLAGNON et al., 2018), com o complemento *Smart-Map* do SIG QGIS, com resolução de pixels de 3,00 x 3,00 m. Posteriormente, uma análise de agrupamento se seguiu para identificar as tendências observadas na área pelos dados gerados pelo monitor, distinguindo possíveis indicações para decisões na gestão da lavoura que podem ser tomadas a partir dos dados gerados pelo sistema.

RESULTADOS E DISCUSSÃO

Ao total, na velocidade de operação recomendada para colheita e com a frequência de coleta em alta resolução do monitor, foram coletados 95.206 pontos na área de estudo. Ao final da filtragem, restaram 55.724 pontos para serem utilizados nas análises. A Tabela 1 mostra a análise descritiva de alguns dos dados, apontados pelo sistema monitor de produtividade.

Com os dados já resumidos, pode-se analisar que, apesar da média ser de 116,00 Mg ha^{-1}, mais de 50,00% destes ficaram abaixo da mesma, o que explicaria também o valor do desvio padrão acima de 30,00. Pode-se inferir também que há área de produtividade com valor próximo a zero, sendo que

do valor mínimo para o primeiro quartil, a produtividade apresenta disparidade considerável, indo de 8,00 para 90,00 Mg ha^{-1}. A massa de impurezas estimada variou entre 0,00 e 73,00 kg ha^{-1}, com valores de assimetria baixo e curtose negativa, em -0,75, evidenciando um achatamento na curva de distribuição dos valores. A velocidade de operação teve média de 1,22 m s^{-1}, com desvio padrão de 0,20 m s^{-1}. A elevação variou em cerca de 16,00 m ao longo da área, com ponto de elevação mínimo em 808,20 m e máximo em 824,10 m, denotando acentuada variação no relevo, o que pode afetar a distribuição espacial da produtividade (NOVAIS et al., 2007).

TABELA 1. Resumo estatístico dos dados de produtividade e elevação da área de estudo, obtidos pelo sistema monitor de produtividade embarcado na colhedora e o receptor do sistema de navegação global por satélite acoplado.,

	Produtividade	Impurezas	Consumo	Velocidade	Elevação
	Mg ha^{-1}	*kg ha^{-1}*	*mL*	*m s^{-1}*	*M*
média	116,49	29,53	12,65	1,22	816,16
θ	36,70	14,28	1,48	0,20	4,03
mín	8,54	0,00	1,25	0,03	808,20
25%	90,20	18,35	11,61	1,11	813,04
50%	114,53	29,08	12,63	1,22	816,48
75%	139,74	40,30	13,61	1,33	819,39
máx	249,81	73,68	18,26	1,92	824,10
ass	0,42	0,14	0,01	-0,40	-0,11
curt	0,22	-0,75	1,07	2,12	-1,07

θ: desvio padrão; mín: valor mínimo observado; 25%: 1º quartil; 50%: 2º quartil; 75%: 3º quartil; máx: valor máximo observado; ass: assimetria; curt: curtose.

Os dados de produtividade demonstraram distribuição próximos à normalidade, com ligeira assimetria e curtose positivas, o que pode ser observado no histograma dos dados (Figura 1). A curtose negativa de massa de impurezas, e positiva de consumo de combustível e velocidade de operação são evidenciadas nos histogramas dos dados, pela curva distribuição dos valores achatada (curtose negativa) ou concentrada (curtose positiva). Os valores de consumo de combustível e velocidade de operação foram os que demonstraram maior quantidade de dados fora do intervalo de confiança, evidenciado pelo boxplot das variáveis. É importante ressaltar que a filtragem ocorreu com foco nos dados de produtividade e que as outras variáveis coletadas pelo monitor foram utilizadas como dados auxiliares ao longo da análise do presente estudo.

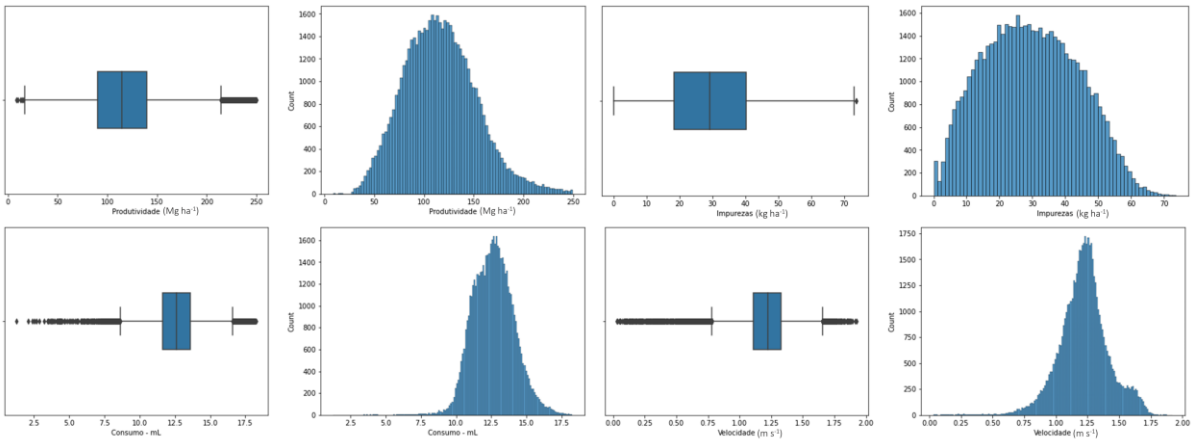


FIGURA 1. Boxplots e histogramas das variáveis produtividade, impurezas, consumo de combustível e velocidade de operação, coletadas pelo sistema monitor de produtividade durante a operação de colheita na área do presente estudo.

O mapa de produtividade da área demonstrou variabilidade espacial acentuada da cultura (Figura 2.A). O efeito de suavização dos valores pela interpolação é conhecido (NAWAR et al., 2017), e foi observado no presente estudo. Os valores mínimos e máximos do vetor de produtividade, observado pelo monitor, e do mapa de produtividade rasterizado, obtido por krigagem ordinária, foram de 8,54/249,81 Mg ha^{-1} e 62,60/151,64 Mg ha^{-1}, respectivamente. A remoção de valores extremos é reportada na literatura após a interpolação e normalmente, apesar de suavizar os valores mínimos e máximos, tende a ser fiel aos quartis do vetor original (NAWAR et al., 2017). Isso também foi observado no presente estudo.

Autores tendem a recorrer à técnica de interpolação por diversos fatores, como: (i) aumentar a densidade de pontos, estimando valores em locais não amostrados; (ii) uniformizar a grade amostral entre diferentes variáveis; (iii) retirar regiões ruidosas, ou apenas discrepantes, dos dados, a fim de facilitar as decisões de gestão (TAYLOR et al., 2007). Entretanto, com o objetivo de tornar a gestão da lavoura cada vez mais local-específica, dados em alta densidade espacial devem estar disponíveis (TAYLOR et al., 2019). Preferencialmente, isso deve ocorrer sem o uso da interpolação, estimando os parâmetros de solo e planta de forma direta na lavoura. Nota-se que os dados coletados pelo monitor de produtividade do presente estudo tornam essa estratégia possível. A colheita da cana-de-açúcar, realizada linha a linha, aliada à frequência de coleta de 1,00 Hz e ao posicionamento GNSS de posicionamento acurado, permitem ao gestor da área identificar a variabilidade da produção de forma minuciosa (Figura 2). Com os dados na densidade de coleta apresentada pelo monitor, futuros trabalhos podem investigar estratégias de adubação, reconhecimento de falhas na fileira de cana-de-açúcar, reconstituição de linhas, entre outras abordagens.

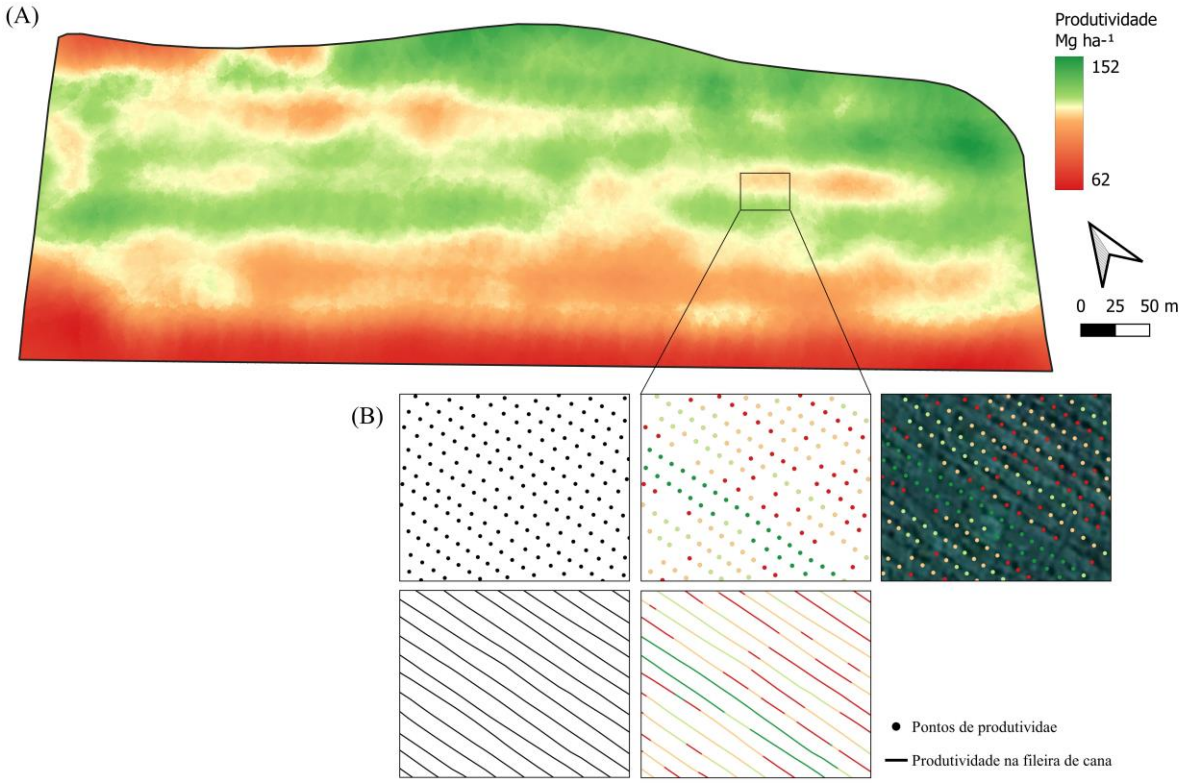


FIGURA 2. (A) Mapa de produtividade da área obtido pela interpolação por krigagem ordinária dos pontos filtrados. (B) No detalhe, uma visão ampliada dos dados coletados na lavoura pelo monitor de produtividade, antes do processo de interpolação, na forma de vetores de pontos e linhas. A partir dos dados obtidos a cada 1,00 s pelo sistema monitor de produtividade, torna-se possível a identificação da variabilidade da cultura linha a linha, em alta resolução espacial.

Apesar da coleta de dados em alta frequência representar um avanço, estratégias de simplificação da gestão devem ser, pelos próximos anos, imperativas, uma vez que não só a identificação da variabilidade, mas a possibilidade de atuar em cima dela, deve ser possível. Para tal, são necessárias máquinas que permitam realizar a distribuição de insumos na mesma densidade amostral com a que os dados são coletados. Se não for possível atuar em escala fina, outras estratégias devem ser adotadas a fim de otimizar a gestão, em busca de melhor alocação de recursos e da consequente sustentabilidade produtiva, objetivo primário da AP (ISPA, 2024).

Uma estratégia a ser adotada é a identificação de variáveis ambientais que tenham relação significativa com a produtividade, para apontar diferentes zonas que permitam ao gestor da área tirar vantagem da variabilidade a fim de tomar decisões mais assertivas. A análise de correlação entre os dados de produtividade, massa de impurezas estimada, consumo de combustível, velocidade de operação e elevação, todas coletados pelo sistema monitor de produtividade do presente estudo, mostrou que a produtividade e a elevação (variável ambiental) possuem correlação alta e significativa a 99% de confiança ($p<0,01$) (Figura 3), em que os dados de produtividade se mostraram inversamente proporcionais à elevação (Figura 4). Isso denota que, quanto mais baixo o relevo dentro dessa área, maior foi a produtividade. Ainda, outras variáveis do motor mostraram correlação significativa com a produtividade, é o caso de consumo de combustível e velocidade de operação, e ainda a massa de impurezas estimada. Isso aumenta a confiabilidade dos dados, uma vez que outros trabalhos demonstram que é possível estabelecer relações entre essas variáveis, podendo ainda calibrar modelos preditivos para a produtividade da cana-de-açúcar, a partir desses parâmetros do motor da colhedora, durante a operação de colheita (MALDANER et al., 2021).

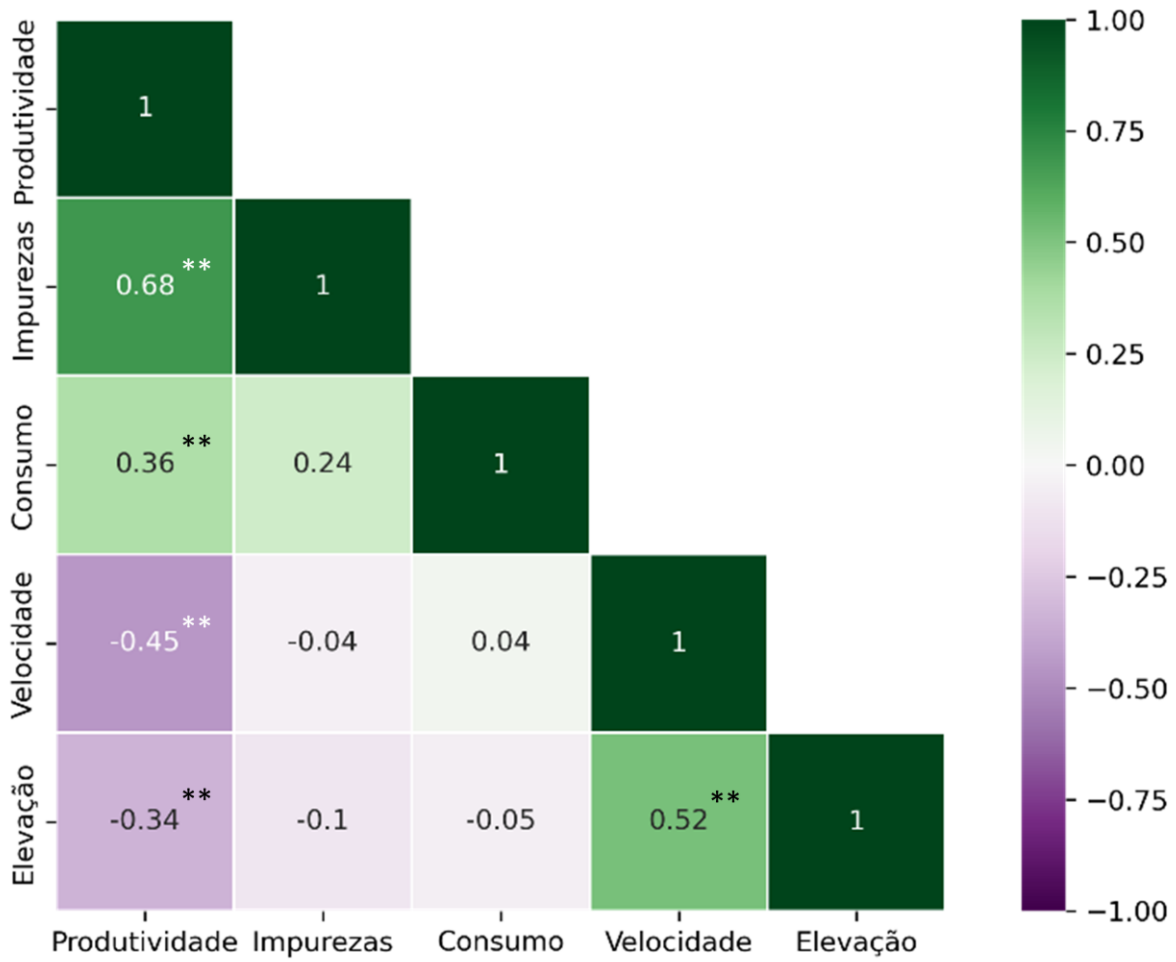


FIGURA 3. Análise de correlação de Pearson (p<0,01, marcados por **) entre os dados de produtividade, massa de impurezas estimada, consumo de combustível, velocidade de operação e elevação, coletados pelo sistema monitor de produtividade na área do presente estudo.

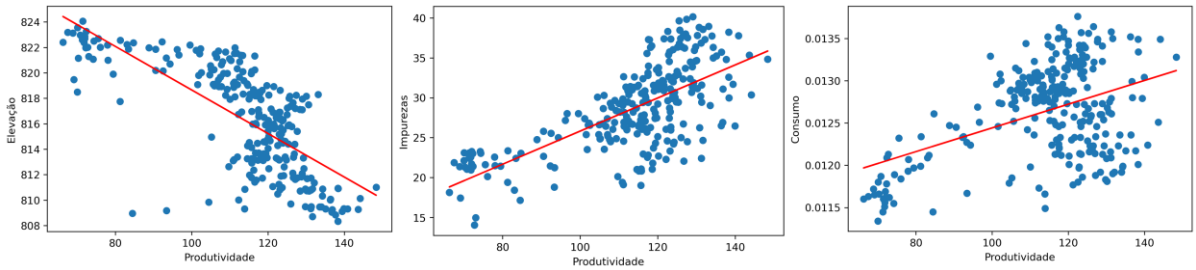


FIGURA 4. Gráfico da regressão linear (p<0,01) e equação da reta entre os pontos de produtividade, elevação, massa de impurezas estimada e consumo de combustível da área do estudo, demonstrando uma tendência inversamente proporcional para elevação, e diretamente proporcional para impurezas e consumo.

Apesar da análise estatística demostrar a variabilidade espacial acentuada da produtividade, que demanda variação na gestão, caso a atuação na área em escala fina não seja possível, a simplificação da gestão por zonas, dividindo a área pela produtividade e outras variáveis ambientais relevantes à gestão, também se mostrou possível pelos dados coletados pelo sistema monitor (Figura 5). A análise de agrupamento denota que existe espaço para explorar a variabilidade na gestão da lavoura, ao invés de considerar as decisões pela média de produtividade. Observam-se três zonas de produtividade, que se mostram bem relacionadas ao perfil de elevação da área. Esse fator pode ser essencial para um maior planejamento e melhor execução de manejos com a finalidade de obter a maior eficiência possível dos recursos disponíveis. A zona de alta produtividade (ZA) apresentou média de 126,49 Mg

ha^{-1}, enquanto a zona de transição (ZT) apresentou 116,21 Mg ha^{-1}, e a zona de baixa produtividade (ZB), 70,94 Mg ha^{-1}.

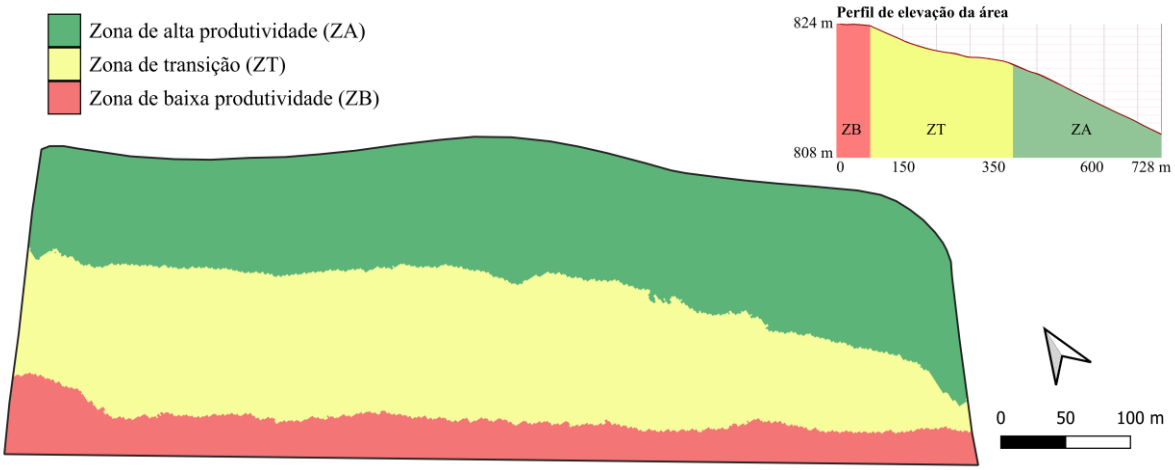


FIGURA 5. Zonas de produtividade separadas pela análise de agrupamento nos dados de produtividade e elevação da área. No canto superior esquerdo, o perfil de elevação da área, com as cores correspondendo às zonas de produtividade identificadas pelos dados do monitor.

A análise dessas zonas de produtividade pode vir a ser um fator que corrobore com a eficiência desse método com sensor óptico da produtividade de cana-de-açúcar, uma vez que a literatura demonstra que a dinâmica da fertilidade do solo tende a acumular, em regiões mais baixas do relevo de uma mesma área, maiores teores de matéria orgânica e nutrientes, culminando em maiores produtividades (GALVÃO et al., 2005; NOVAIS et al., 2007; SANTOS et al., 2008; SILVA et al., 2008; SANCHEZ et al., 2009; RICHTER et al., 2011).

Nessa linha, pode-se discorrer que o monitor de produtividade apresentado neste estudo, que se tornou recentemente disponível para o setor, comprovou elevado potencial de uso para a AP. Sendo um método de estimar a produtividade de forma direta, pelo volume de cana-de-açúcar colhido, com alta densidade de coleta (1,00 Hz), e elevada acurácia de posicionamento, permitindo identificar a variabilidade linha a linha e mostrando-se diversas as aplicações possíveis dos dados gerados pelo monitor. No entanto, para aferir exatamente a eficiência desse método de mensurar a produtividade, entretanto, futuros trabalhos podem aferir a estimação de produtividade pelo sistema monitor com células de carga no transbordo da colheita, na mesma linha de MALDANER et al. (2022), que comprovou a eficiência da geração de mapas de produtividade de cana-de-açúcar a partir de parâmetros indiretos, estimando a massa colhida pelas variações na pressão do óleo do motor de corte de base da colhedora. Ainda, pode-se adicionar o fator temporal, gerando mapas em colheitas consecutivas em uma mesma área, ou trabalhos com taxas variáveis a partir da alta densidade de pontos, como testar diferentes doses de fertilizantes para cada zona de produtividade, ou até mesmo doses ponto a ponto, entre outras possibilidades.

CONCLUSÃO

Com base nos dados e análises apresentadas, pode-se inferir que o sensor óptico de produtividade para cana-de-açúcar fornece dados suficientes para a realização de mapas de produtividade, e estes, por sua vez, se mostraram capazes de servir como base para a diferenciação do manejo com base na heterogeneidade dos atributos do talhão. No entanto, é requerida atenção para as etapas de filtragem e interpolação desses dados, principalmente por se tratarem de dados georreferenciados na cana-de-açúcar, onde a variabilidade pode ser expressa na linha da cultura. Com a coleta em alta resolução espacial, e posicionamento preciso desses dados na lavoura, sugere-se a possibilidade de trabalhar

com a variabilidade de forma individual para cada linha da cultura, incorporando maior assertividade à gestão agrícola.

AGRADECIMENTOS

Agradeço à John Deere por ceder os dados que foram utilizados neste trabalho.

REFERÊNCIAS

ARAÚJO, EA de, et al. "Aspectos gerais dos solos do Acre com ênfase ao manejo sustentável." **Manejo do solo e recomendação de adubação para o estado do Acre**. WADT, PGS (Ed.). Rio Branco: Embrapa, 27-62, 2005.

BENJAMIN, C. E.; MAILANDER, M. P.; PRICE, R. R. Sugar cane yield monitoring system. In: **2001 ASAE Annual Meeting**. American Society of Agricultural and Biological Engineers, p. 1., 1998.

BORDONAL, R. O. et al. Sustainability of sugarcane production in Brazil. A review. **Agronomy for sustainable development**, v. 38, p. 1-23, 2018.

CARRER, M. J. et al. Precision agriculture adoption and technical efficiency: An analysis of sugarcane farms in Brazil. **Technological Forecasting and Social Change**, v. 177, p. 121510, 2022.

CHERUBIN, M. R. et al. Land use and management effects on sustainable sugarcane-derived bioenergy. **Land**, v. 10, n. 1, p. 72, 2021.

COELHO, A. M. Agricultura de precisão: manejo da variabilidade espacial e temporal dos solos e culturas. Sete Lagoas, **Embrapa Milho e Sorgo**, 2005.

CORREDO, L. P. et al. Sugarcane harvester for in-field data collection: State of the art, its applicability and future perspectives. **Sugar Tech**, v. 23, n. 1, p. 1-14, 2021.

COX, G.; HARRIS, H.; COX, D. Application of precision agriculture to sugar cane. In: **Proceedings of the Fourth International Conference on Precision Agriculture**. Madison, WI, USA: American Society of Agronomy, Crop Science Society of America, Soil Science Society of America, p. 753-765, 1999.

DALL'AGNOL, R. W. ; BETZEK, N. M.; BAZZI, C. L.. Aplicação do software R para análise geoestatística, interpolação de dados por krigagem ordinária e geração de mapas temáticos de produtividade agrícola. **Revista de Computação aplicada ao Agronegócio**, v. 1, n. 1, p. 24-37, 2018.

DE SOUZA, G. S. et al. Krigagem ordinária e inverso do quadrado da distância aplicados na espacialização de atributos químicos de um argissolo. **Scientia agraria**, v. 11, n. 1, p. 073-081, 2010.

GALVÃO, S. R. S.; SALCEDO, I. H.; SANTOS, A. C. Frações de carbono e nitrogênio em função da textura, do relevo e do uso do solo na microbacia do agreste em Vaca Brava (PB). **Revista Brasileira de Ciência do Solo**, v. 29, p. 955-962, 2005.

INTERNATIONAL SOCIETY OF PRECISION AGRICULTURE. (2024). Precision Agriculture definition. Disponível em: <https://www.ispag.org/about/definition>. Acesso em: 24 de fevereiro de 2024

JOHN DEERE. Harvest Monitor. Disponível em: https://www.deere.com.br/pt/agricultura-de-precis%C3%A3o/solu%C3%A7%C3%B5es-para-opera%C3%A7%C3%B5es-no-campo/harvest-monitor/. Acesso em: 23 de fevereiro de 2024

KLUYVERT, T. et al. Jupyter Notebooks-a publishing format for reproducible computational workflows. **Elpub**, 87-90, *2016*.

MAGALHÃES, P. S.G.; CERRI, D. G. P. Yield monitoring of sugar cane. **Biosystems Engineering**, v. 96, n. 1, p. 1-6, 2007.

MALDANER, L. F. et al. Predicting the sugarcane yield in real-time by harvester engine parameters and machine learning approaches. **Computers and Electronics in Agriculture**, v. 181, p. 105945, 2021.

MOLIN, J. P.; Definição de unidades de manejo a partir de mapas de produtividade. **Engenharia Agrícola**, v. 22, n. 1, p. 83-92, 2002.

MOLIN, J. P.; DO AMARAL, L. R.; COLAÇO, A. **Agricultura de precisão**. Oficina de textos, 2015.

MOLIN, J.P.; WEI, M.C.F.; DA SILVA, E.R.O. Challenges of Digital Solutions in Sugarcane Crop Production: A Review. **AgriEngineering**, 6, 925-946, 2024.

NAWAR, S. et al. Delineation of soil management zones for variable-rate fertilization: A review. **Advances in agronomy**, v. 143, p. 175-245, 2017.

NOVAIS, R. F. et al. (Eds.). Fertilidade do solo. Viçosa, MG: **Sociedade Brasileira de Ciência do Solo**, 2007.

PEREIRA, G. W. et al. Smart-map: An open-source QGIS plugin for digital mapping using machine learning techniques and ordinary kriging. **Agronomy**, v. 12, n. 6, p. 1350, 2022.

QGIS.org (2023). QGIS Geographic Information System. Open Source Geospatial Foundation Project. http://qgis.org

RICHTER, R. L. et al. Variabilidade espacial de atributos da fertilidade de um Latossolo sob plantio direto influenciados pelo relevo e profundidade de amostragem. **Enciclopédia biosfera**, v. 7, n. 13, 2011.

SANCHES, G. M. et al. Comprehensive assessment of spatial soil variability related to topographic parameters in sugarcane fields. **Geoderma**, v. 362, p. 114012, 2020.

SANCHEZ, R. B. et al. Variabilidade espacial de atributos do solo e de fatores de erosão em diferentes pedoformas. **Bragantia**, v. 68, p. 1095-1103, 2009.

SANTOS, A. C.; SALCEDO, I. H.; GALVÃO, S. R. S. Relações entre uso do solo, relevo e fertilidade do solo em escala de microbacia. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 12, p. 458-464, 2008.

SILVA, F. M. et al. Variabilidade espacial de atributos químicos e de produtividade na cultura do café. **Ciência Rural**, v. 37, p. 401-407, 2007.

SMITH, P. et al. Global change pressures on soils from land use and management. **Global change biology**, v. 22, n. 3, p. 1008-1028, 2016.

SCHLEIFER, P. Private regulation and global economic change: The drivers of sustainable agriculture in Brazil. **Governance**, v. 30, n. 4, p. 687-703, 2017.

TAYLOR, J. A. et al. Zoning and data fusion in precision horticulture: current and needed capabilities to assist decision-making. In: **International Symposium on Precision Management of Orchards and Vineyards 1314**, p. 173-188, 2019.

TAYLOR, J. A.; MCBRATNEY, A. B.; WHELAN, B. M. Establishing management classes for broadacre agricultural production. **Agronomy Journal**, v. 99, n. 5, p. 1366-1376, 2007.

USO DE APRENDIZADO DE MÁQUINA PARA AVALIAR EFEITOS CAUSADOS POR UMIDADE NA ESPECTROSCOPIA DO SOLO

Gabriel Movio Nalin [1]; Ricardo Canal Filho [2]; José Paulo Molin [3]

[1]Graduando em Engenharia Agronômica, Depto. De Engenharia de Biossistemas. Avenida Pádua Dias, 11, 13418-900, Piracicaba, São Paulo, Brasil. Universidade de São Paulo - Escola Superior de Agricultura 'Luiz de Queiroz; [2]Engenheiro agrônomo, Doutorando, Depto. De Engenharia de Biossistemas. Avenida Pádua Dias, 11, 13418-900, Piracicaba, São Paulo, Brasil. Universidade de São Paulo - Escola Superior de Agricultura 'Luiz de Queiroz; [3]Engenheiro Agrícola, Professor Titular, Depto. De Engenharia de Biossistemas. Avenida Pádua Dias, 11, 13418-900, Piracicaba, São Paulo, Brasil. Universidade de São Paulo - Escola Superior de Agricultura 'Luiz de Queiroz

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A espectroscopia de refletância no infravermelho próximo e visível (VNIR) é amplamente estudada como método rápido e econômico para inferir quantitativamente as propriedades do solo, visando melhorar a densidade amostral e possibilitar recomendações mais precisas para a produção agrícola. Este estudo avaliou a interferência da umidade na determinação de sete atributos-chave de fertilidade do solo (argila, areia, matéria orgânica, capacidade de troca catiônica, cálcio, magnésio e potássio), utilizando 72 amostras de solo coletadas em campo. Os dados brutos foram empregados para calibrar modelos preditivos via regressão de componentes principais (PCR). Verificou-se que, para parâmetros como matéria orgânica, capacidade de troca catiônica, potássio, cálcio e magnésio, as validações da análise úmida mostraram valores de R^2 superiores em comparação com a análise seca. Os resultados sugerem que a umidade, inicialmente considerada interferente nos espectros NIR, não necessariamente prejudica o desempenho dos modelos de previsão. Além disso, a utilização da regressão de componentes principais emerge como uma alternativa viável para o tratamento prévio das amostras de solo, o que elimina a necessidade de procedimentos como a homogeneização de partículas e superfícies, bem como a moagem e peneiramento.

PALAVRAS-CHAVE: aprendizado de máquina; espectroscopia no infravermelho próximo; quimiometria

ABSTRACT

Reflectance spectroscopy in the near and visible infrared (VNIR) is widely used as a fast and economical method to quantitatively infer soil properties, aiming to improve sampling density and enable more accurate recommendations for agricultural production. This study evaluated the interference of moisture in the determination of seven key soil fertility attributes (clay, sand, organic matter, cation exchange capacity, calcium, magnesium, and potassium), using 72 soil samples collected in the field. The raw data was used to calibrate predictive models via principal component regression (PCR). It was found that, for parameters such as organic matter, cation exchange capacity, potassium, calcium and magnesium, the wet analysis validations showed higher R^2 values compared to the dry analysis. The results suggest that humidity, initially considered an interfering factor in NIR spectra, does not necessarily impair the performance of prediction models. Furthermore, the utilization of principal component regression emerges as a viable alternative for the pre-treatment of soil samples, which eliminates the need for procedures such as particle and surface homogenization, as well as grinding and sieving.

KEYWORDS: amostras de solo; análise de solo;

INTRODUÇÃO

A análise de solo desempenha um papel crucial no diagnóstico das condições edáficas, fornecendo uma visão abrangente dos atributos químicos, físicos e biológicos do solo. Essa prática é fundamental para avaliar a capacidade do solo de fornecer nutrientes essenciais às plantas, sua textura, sua capacidade de retenção de água e outros aspectos relevantes para a produção agrícola. Para garantir a precisão e representatividade dos resultados da análise de solo, é essencial adotar procedimentos adequados de coleta de amostras. A recomendação dominante é a coleta de uma amostra por hectare, uma prática que os pesquisadores identificaram como a quantidade mínima necessária para manter a significância estatística dos dados obtidos. As densidades de amostragem comumente utilizadas na maioria das lavouras demonstram ser ineficazes na captura adequada da variabilidade dos atributos (Wollenhaupt et al., 1994; Montanari et al., 2012; Cherubin et al., 2014; Cherubin et al., 2015). Como resultado, a representatividade dos dados é comprometida, afetando a precisão das recomendações de fertilizantes e corretivos a serem aplicados no solo. Uma alternativa para análise de solo convencional é o uso da espectroscopia de reflectância. A espectroscopia de refletância no visível e no infravermelho próximo (VNIR, 350-2500 nm) é uma técnica rápida, econômica e não destrutiva para determinar atributos do solo. Além disso, exige apenas uma preparação mínima das amostras e não gera resíduos químicos perigosos (Stenberg et al., 2010). Apesar de ser um conceito interessante, o maior obstáculo para a implementação de bibliotecas espectrais de solo em aplicações de campo reside na diversidade de níveis de umidade do solo. Muitos autores relatam que a umidade gera ruído no sinal coletado pelo sensor, reduzindo o desempenho preditivo de modelos de aprendizado de máquina aplicados aos dados. Com isso, um pré-processamento das amostras, que normalmente envolve secagem, moagem e peneiramento é frequentemente aplicado a amostras de solo antes da coleta espectral. Neste sentido, este trabalho se propõe a avaliar a interferência causada pela umidade de amostras, com preparação mínima antes da coleta de espectros NIR, na predição de atributos do solo por modelos de aprendizado de máquina.

OBJETIVOS

Este estudo avaliou a interferência da umidade na determinação de sete atributos-chave de fertilidade do solo (argila, areia, matéria orgânica, capacidade de troca catiônica, cálcio, magnésio e potássio).

MATERIAL E MÉTODOS

A área utilizada para realização do experimento, de aproximadamente 6,0 ha, está localizada no campus da ESALQ/USP, em Piracicaba, SP. A textura do solo da área de estudo é classificada como franco-arenosa, com teor médio de argila variado entre 10 e 13%. Em novembro de 2021, foram coletadas 72 amostras de solo na área, que foram enumeradas de 1 a 72, e subdivididas em dois grupos para serem submetidas para coleta espectral e para análise em laboratório tradicional. Para realizar a coleta espectral em bancada, o espectro do infravermelho próximo (NIR) das amostras de solo foi obtido enquanto elas estavam em condições de umidade de campo. Em seguida, as amostras foram pesadas e colocadas em uma estufa com ventilação forçada a uma temperatura de 105°C por 72 horas para secagem. Após o período de secagem, as amostras foram pesadas novamente para determinar a umidade de campo no momento da primeira coleta espectral, por meio da Equação 1.

$$\theta(porcentagem) = m_u/m_s \times 100 = (m_u - m_s)/m_s \times 100 \quad \text{Eq. (9)}$$
(1)

em que θ: umidade gravimétrica do solo, em porcentagem;

mu Eq. (10)
: massa de solo úmido;

ms Eq. (11)
: massa de solo seco.

Depois, o espectro NIR foi novamente coletado, mantendo a condição em que as amostras saíram do campo (sem moagem e peneiramento), mas com o solo seco. O segundo grupo foi encaminhado para um laboratório responsável por realizar as análises de solo. Os atributos analisados neste estudo foram a matéria orgânica (MO) e a capacidade de troca catiônica (CTC), bem como os teores de potássio (K), cálcio (Ca) e magnésio (Mg) trocáveis no solo. Para a determinação da matéria orgânica, foi empregado o método de oxidação. Já a capacidade de troca catiônica foi calculada considerando as bases mais a acidez total do solo. Os teores de potássio, cálcio e magnésio trocáveis foram analisados utilizando o método de extração com resina.

A aquisição dos dados espectrais foi realizada com o espectrômetro MicroNIR OnSite-W (Viavi Solutions Inc., CA, EUA) com resolução espectral de 908,1-1676,2 nm, com leituras a cada 6,2 nm, resultando em 125 diferentes comprimentos de onda. Os espectros foram coletados na base do compartimento, através de uma janela de safira, transportados por um cabo USB e convertidos para transmissão por meio de um cabo Ethernet, sendo gravados em um computador portátil conectado ao conjunto (Figura 1). Uma placa de 99% reflectância foi usada como referência do branco (máxima reflectância), e o próprio equipamento possui medição interna de referência do preto (mínima reflectância).



FIGURA 1. Espectrômetro MicroNIR OnSite-W e seus componentes (Viavi Solutions Inc., CA, EUA).

O processamento dos dados espectrais ocorreu no ambiente de programação do software RStudio (RSTUDIO TEAM, 2023). Os dados brutos coletados pelo sensor foram utilizados para calibrar modelos preditivos via regressão de componentes principais (PCR), uma técnica muito aplicada a dados multivariados como espectros NIR do solo, pois consegue reduzir dados ruidosos, redundantes e esparsos (AGARWAL et al., 2021; CHANG et al., 2001). A PCR ocorre em três etapas: (a) uma análise de componentes principais (PCA) é aplicada em toda a matriz de dados; (b) uma regressão linear é usada para obter o vetor de coeficientes de regressão estimados; (c) os autovetores da PCA são usados para obter os estimadores da PCR (Equação 2):

$$(\beta_k)\hat{} = v_k(\delta_k)\hat{} \qquad \text{Eq. (12)}$$

(2)

em que β? = estimador da PCR, k pertence de {1, ..., *p*}, *p* = número de covariáveis, V = conjunto ortonormal de autovetores, ?? = vetor de coeficientes dos regressores estimados.

Os modelos preditivos foram calibrados e posteriormente avaliados pelo processo de validação independente, i.e., utilizando amostras que não estiveram presentes na calibração do modelo. Para isso, as 72 amostras de solo foram divididas na proporção de 70% para calibração e 30% para validação, utilizando a técnica de validação cruzada k-fold com k = 10. Esta abordagem é recomendada para a avaliação de modelos de aprendizado de máquina, pois tende a fornecer uma estimativa mais imparcial ou conservadora da capacidade do modelo em comparação com outros métodos (JUNG et al., 2018). Basicamente, o processo envolve as seguintes etapas: 1) embaralhamento aleatório dos dados; 2) divisão dos dados em k grupos; 3) para cada grupo, um grupo é mantido como conjunto de validação, enquanto k-1 grupos restantes são combinados e utilizados como conjunto de treinamento para ajustar um modelo, que é então avaliado no conjunto de validação e descartado, repetindo-se esse processo para todos os grupos; 4) a habilidade do modelo é resumida pela média das avaliações realizadas. Isso garante que cada amostra seja utilizada uma vez no conjunto de validação e k-1 vezes no conjunto de treinamento, proporcionando uma estimativa mais imparcial da capacidade preditiva do modelo.

As métricas utilizadas para avaliação dos modelos preditivos foram o coeficiente de determinação (R^2), a raiz do erro quadrático médio (RMSE) e o erro médio absoluto (MAE). Quanto maior o valor do R^2, e menores o RMSE e MAE, subentende-se que melhor foi o desempenho dos modelos.

Características espectrais dos espectros úmidos e secos, como intensidade, morfologia e feições de absorção, também foram comparadas a fim de avaliar a influência da umidade nos espectros NIR, e avaliar possíveis interferências notadas pelos modelos preditivos. Para isso, foram utilizadas técnicas de pré-processamento para comparação entre os dois grupos, como a variação normal padrão (SNV), que é um dos métodos de correção de espalhamento mais comuns utilizados em espectros NIR, proposto para remover a interferência multiplicativa do tamanho da partícula (BARNES et al., 1989). A SNV permite centralizar os espectros no valor zero, o que facilita a comparação entre dois grupos coletados em diferentes momentos, pela variação na intensidade e nas feições de absorção a partir desse valor nulo.

RESULTADOS E DISCUSSÃO

Os resultados das validações dos modelos preditivos construídos com base em análises úmidas e secas estão resumidos na Tabela 1. Os parâmetros de MO, CTC, K, Ca e Mg, as validações da análise úmida revelaram valores de R^2 superiores em comparação com a análise seca. Um R^2 mais elevado indica um desempenho superior do modelo, uma vez que este parâmetro indica a porcentagem da variância dos dados observados que foi explicada pelo modelo (dados preditos). Adicionalmente, o modelo preditivo relacionado à análise úmida exibe maiores valores de RMSE para CTC e Ca, bem como valores de MAE superiores para MO, CTC e Ca, em comparação com a análise seca. No entanto, a análise seca revelou configurações otimizadas para MO, K e Mg em termos de RMSE, com valores menores, mas registrou valores maiores de MAE para K e Mg.

TABELA 1. Resultados de validação dos modelos de regressão via componentes principais validação utilizando validação cruzada k-fold.

					Análise úmida				Análise seca		
min	max	a	pc	R^2	RMSE	MAE	NC	R^2	RMSE	MAE

Mo	12,0	35,0	23,0	7	0,86	2,29	1,92	5	0,74	2,76	1,85
CTC	44,5	68,4	23,9	5	0,83	4,54	3,36	4	0,64	3,43	2,79
K	0,4	5,0	4,6	5	0,64	0,72	0,61	8	0,46	0,86	0,72
Ca	10,0	34,0	24,0	8	0,50	2,65	2,09	2	0,40	2,10	1,56
Mg	5,0	22,0	17,0	5	0,32	1,53	1,31	2	0,19	1,66	1,43

min, max, a: mínimo, máximo, e amplitude dos valores observados no banco de dados; pc: número de componentes principais utilizados na regressão; R^2: coeficiente de determinação; RMSE: raiz do erro quadrático médio; MAE: erro médio absoluto; MO: matéria orgânica, g dm^{-3}; CTC: capacidade de troca catiônica, $mmol_c$ dm^{-3}; K: potássio trocável, $mmol_c$ dm^{-3}; Ca: cálcio trocável, $mmol_c$ dm^{-3}; Mg: magnésio trocável, $mmol_c$ dm^{-3}.

A análise do espectro médio de reflectância das 72 amostras de solo secas comparadas ao espectro médio dessas mesmas amostras úmidas comprova que, com a maior presença de água, houve maior absorção da luz NIR (Figura 2). Isso corrobora com o descrito na literatura, observando que a água tende a reduzir a intensidade do espectro (NOCITA et al., 2013; MORELLOS et al., 2016; YI-PING WANG et al., 2020). A análise de morfologia e características espectrais entre os espectros de análise úmida e seca demonstrou diferenças que se repetiram entre as 72 amostras analisadas. Essas diferenças estão ilustradas na Figura 3. A intensidade das feições de absorção aumentou consideravelmente (Figura 3.A). Onde essas feições tiveram intensidade aumentada, houve ainda um prolongamento nos vales formados, principalmente entre 1400 e 1500 nm (Figura 3.B). Entretanto, os espectros conservaram interações solo-espectro entre a análise úmida e seca, com feições, vales e picos de absorção nos mesmos comprimentos de onda. Após 1400 nm, entretanto, é notável que a taxa de reflectância aumentou muito mais no espectro úmido do que no espectro de análise seca (Figuras 3.C e 3.D).

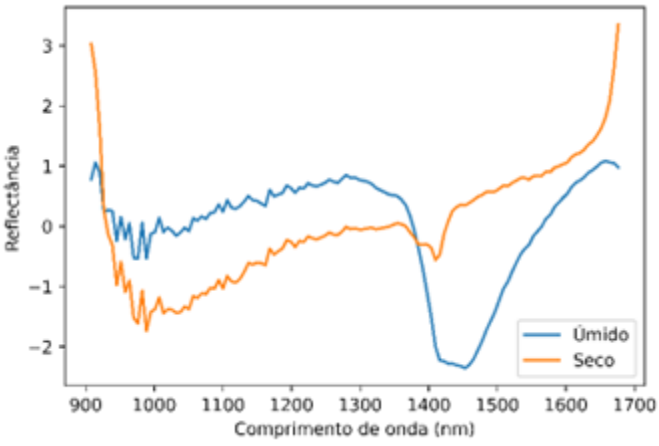


FIGURA 2. Espectro médio das 72 amostras de solo seco e úmido.

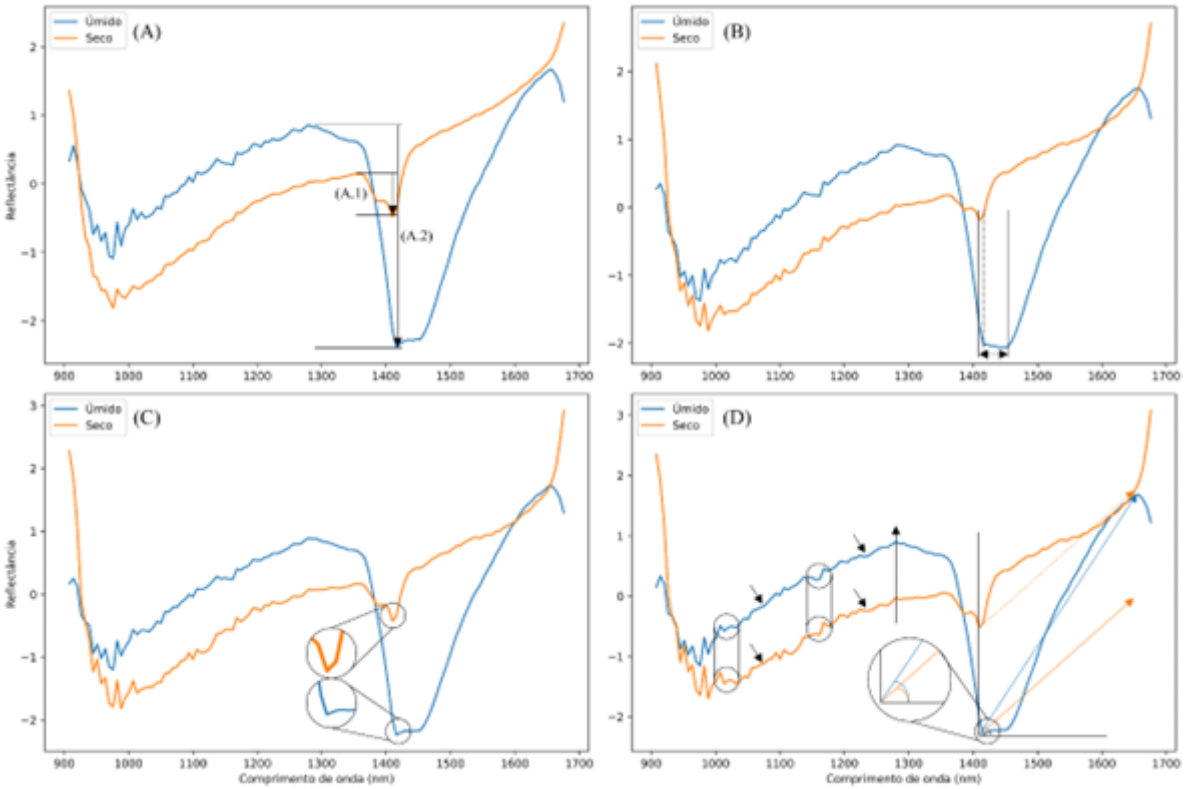


FIGURA 3. Comparação entre quatro amostras de solo e seus respectivos espectros úmidos e secos, destacando feições de absorção, intensidade e morfologia semelhantes e discrepantes entre os dois grupos.

Os valores de R^2 mais próximos de 1 obtidos nas validações dos modelos preditivos elaborados com base em análises úmidas podem ser atribuídos aos efeitos do umedecimento nos espectros de refletância. Quando o solo está molhado, sua capacidade de reflexão da luz diminui em comparação com quando está seco. Isso ocorre porque a presença de água, tanto na superfície quanto nos poros do solo, altera a maneira como a luz é dispersa. A água modifica o índice de refração ao redor das partículas do solo, passando de ar para água, resultando em menos contraste e mais dispersão direta da luz. Isso faz com que a luz percorra um caminho mais longo antes de ser reemitida, aumentando assim a absorção pelo solo (YI-PING WANG et al., 2020).

É importante ressaltar que os resultados obtidos neste estudo diferem do que alguns autores relatam. A umidade do solo é, por vezes, tratada como indesejável para construir modelos preditivos a partir de espectros NIR (STENBERG et al., 2010; NOCITA et al., 2015). Ainda, outro ponto a ser destacado é o de que, mesmo com a coleta espectral sendo realizada sem pré-tratamento das amostras de solo quanto a uniformização de partículas e superfície, pela moagem e peneiramento do solo, os modelos preditivos foram capazes de predizer de forma robusta os atributos do solo. A fim de evitar os efeitos da umidade e de uniformizar a superfície da amostra para coleta, autores recorrem a técnicas morosas de secagem, moagem e peneiramento (DEMATTÊ et al., 2017; CEZAR et al., 2019). Além de levar tempo e dispender mão de obra para tais atividades, aumentando o tempo entre a amostra chegar ao laboratório e a análise estar disponível ao produtor, os resultados reportados mostram que nem sempre isso pode representar ganhos no desempenho preditivo dos modelos. Isso corrobora com o encontrado por YI-PING WANG et al. (2020), que também reportaram melhores modelos preditivos de MO com um nível adequado de umidade no solo no momento da coleta espectral NIR, em detrimento da coleta com o solo seco.

Os efeitos observados no presente estudo podem ser divididos entre dois fatores: (i) a técnica de modelagem preditiva, utilizando um modelo de redução de dimensionalidade; e (ii) a interação

específica da água com o espectro NIR e com feições relacionadas à MO. A modelagem preditiva com a técnica de PCR provê a redução da dimensionalidade do espectro. As 125 variáveis originais, inseridas na calibração do modelo, são transformadas em combinações lineares, conhecidas como componentes principais da variância dos dados. Dessa forma, a PCR utiliza uma extração de variáveis de forma a preservar a estrutura original de variância, o que perde poucas informações do banco de dados original, garantindo ainda a redução de dados ruidosos, esparsos e covariáveis, que reduziriam o desempenho do modelo (JOLLIFFE et al., 2011; AGARWAL et al., 2019; VELLIANGIRI et al., 2019). Entende-se, portanto, que a PCR foi capaz de atuar como um pré-processamento de espectros, sendo capaz de automatizar o processo de limpeza dos dados que normalmente é realizado por técnicas de escolha manual de pré-processamento espectral. Esse efeito benéfico da técnica também é reportado por outros autores para a predição de atributos do solo por espectros NIR (CANAL FILHO, 2023) e de raio-x de fluorescência (WEI et al., 2022).

A interação da água com o espectro NIR e com feições relacionadas à MO também pode explicar os resultados obtidos nesse estudo. Água e argila são conhecidas por ter um efeito de aumento nas feições de absorção do espectro NIR, e redução da intensidade de reflectância do espectro (TERRA et al., 2018; YI-PING WANG et al., 2020). Ainda, as feições de água e argila no NIR podem se sobrepor em sobretons observados entre 1400 e 1500 nm (STENBERG et al., 2010; NOCITA et al., 2015; PASQUINI et al., 2018). Entretanto, em uma área de textura franco-arenosa como a do presente estudo, com teores médios de argila entre 10 e 13%, sabe-se que a MO pode desempenhar papel fundamental na física e fertilidade do solo. A MO também possui, naturalmente, propriedades elevadas de absorção de água (SHEPERD et al., 2002; WEIL & BRADY, 2017). Dessa forma, sugere-se que essas interações da MO com a água, e a resposta espectral semelhante, de redução da intensidade de reflectância e aumento da intensidade das feições de absorção, foi o mecanismo utilizado pelos modelos preditivos que permitiram a melhora do desempenho a partir de espectros úmidos, ao invés de espectros secos.

Para os outros atributos preditos neste trabalho, CTC, K, Ca e Mg, o mecanismo foi, provavelmente, o mesmo da MO, e por isso os resultados reportados demonstram tendência semelhante. A CTC e os nutrientes de plantas não possuem feições de absorção no NIR (STENBERG et al., 2010; NOCITA et al., 2015), portanto, sua predição com essa região espectral depende de calibrações indiretas, em locais onde existe uma covariância entre um atributo de resposta primária (argila, MO, água). Ainda, a MO pode representar até 90% da CTC em solos de textura arenosa (WEIL & BRADY, 2017). A partir daí, uma vez que a CTC é diretamente proporcional à quantidade de cargas negativas do solo, que atraem os cátions de K, Ca e Mg, compreende-se o mecanismo de predição desses atributos no presente estudo, e a resposta ao umedecimento dos espectros semelhante ao observado para os modelos de MO.

Os resultados reportados neste trabalho indicam que nem sempre a umidade, tratada como ruído na espectroscopia NIR de solo, terá efeito negativo no desempenho de modelos preditivos. Muitas vezes, ainda, ela pode ter um efeito sinérgico com a predição de determinados atributos, o que corrobora com outros trabalhos da literatura. Uma vez que a moagem e peneiramento também não foram necessárias para os resultados satisfatórios apresentados neste trabalho, sugere-se que essas etapas de pré-processamento de amostras e espectros podem ser avaliadas e, algumas vezes, substituídas por técnicas que lidem com isso de forma automática (como a PCR). Isso pode ser importante para o crescimento da espectroscopia NIR na análise de solo em laboratório

CONCLUSÃO

Este trabalho avaliou a interferência causada pela umidade em amostras de campo, com preparação mínima antes da coleta de espectros NIR, na predição de atributos do solo por modelos de aprendizado de máquina. Os resultados apresentados sugerem que a presença de umidade, inicialmente considerada como interferência nos espectros NIR do solo, não necessariamente prejudica o

desempenho dos modelos de previsão. Em algumas situações, observa-se uma interação positiva entre a umidade e a predição de certos atributos, em consonância com descobertas anteriores documentadas na literatura científica. Adicionalmente, foi constatado que certas técnicas, como a regressão de componentes principais, podem ser empregadas como método de pré-processamento das amostras. Isso pode eliminar a necessidade de tratamentos prévios das amostras de solo, tais como uniformização de partículas e superfície, bem como moagem e peneiramento do solo. Ainda, pode representar um avanço positivo para o desenvolvimento da técnica em sensoriamento proximal do solo, coletando espectros diretamente no campo, onde a umidade, granulometria e superfície amostral são fatores mais difíceis de controlar.

AGRADECIMENTOS

À Spectral Solutions Comércio e Serviços Ltda. pela parceria que ofereceu o sensor utilizado neste estudo

REFERÊNCIAS

AGARWAL, A.; SHAH, D.; SHEN, D.; SONG, D. On Robustness of Principal Component Regression. In: **Advances in Neural Information Processing Systems**. NeurIPS: New Orleans, LA, USA, 2021.

BARNES, R. J.; DHANOA, M. S.; LISTER, S. J. Standard Normal Variate Transformation and De-trending of Near-Infrared Diffuse Reflectance Spectra. **Applied Spectroscopy**, v. 43, n. 5, p. 772-777, 1989.

CANAL FILHO, R. Online Near-Infrared Spectroscopy for Soil Attributes Prediction. Master's thesis, Universidade de São Paulo, 2023.

CANAL FILHO, R. et al. Soil Attributes Mapping with Online Near-Infrared Spectroscopy Requires Spatio-Temporal Local Calibrations. **AgriEngineering**, v. 5, n. 3, p. 1163-1177, 1 set. 2023.

CEZAR, E.; NANNI, M. R.; GUERRERO, C.; da SILVA JUNIOR, C. A.; CRUCIOL, L. G. T.; CHICATI, M. L.; SILVA, G. F. C. Organic Matter and Sand Estimates by Spectroradiometry: Strategies for the Development of Models with Applicability at a Local Scale. **Geoderma**, v. 340, p. 224-233, 2019.

CHANG, C.W.; LAIRD, D.A.; MAUSBACH, M.J.; HURBURGH, C.R. Near?Infrared Reflectance Spectroscopy-Principal Components Regression Analyses of Soil Properties. **Soil Science Society of America Journal**, v. 65, p. 480-490, 2001.

DEMATTÊ, J. A. M.; RAMIREZ-LOPEZ, L.; MARQUES, K. P. P.; RODELLA, A. A. Chemometric Soil Analysis on the Determination of Specific Bands for the Detection of Magnesium and Potassium by Spectroscopy. **Geoderma**, v. 288, p. 8-22, 2017.

JOLLIFFE, I. Principal Component Analysis. **Springer Berlin Heidelberg**, 2011, pp. 1094-1096.

MARSTON et al. Effects of External Factors on Soil Reflectance Measured On-The-Go and Assessment of Potential Spectral Correction through Orthogonalisation and Standardisation Procedures. **Geoderma**, v. 177, p. 19-36, 1 abr. 2018.

MORELLOS, A. et al. Machine Learning Based Prediction of Soil Total Nitrogen, Organic Carbon and Moisture Content by Using VIS-NIR Spectroscopy. **Biosystems Engineering**, v. 152, p. 104-116, dez. 2016.

NOCITA, M. et al. Prediction of Soil Organic Carbon for Different Levels of Soil Moisture Using Vis-NIR Spectroscopy. **Geoderma**, v. 199, p. 37-42, maio 2013.

NOCITA, M. et al. Soil Spectroscopy: An Alternative to Wet Chemistry for Soil Monitoring. **Advances in Agronomy**, v. 132, p. 139-159, 2015.

PASQUINI, C. Near Infrared Spectroscopy: A Mature Analytical Technique with New Perspectives - A Review. **Analytica Chimica Acta**, v. 1026, p. 8-36, out. 2018.

RICKLEMYER, R. S.; BROWN, D. J. On-the-Go VisNIR: Potential and Limitations for Mapping Soil Clay and Organic Carbon. **Computers and Electronics in Agriculture**, v. 70, n. 1, p. 209-216, jan. 2010.

RSTUDIO TEAM. RStudio: Integrated Development for R. RStudio, PBC, Boston, MA. URL http://www.rstudio.com/, 2020.

SHEPHERD, M. A.; HARRISON, R.; WEBB, J. Managing Soil Organic Matter-Implications for Soil Structure on Organic Farms. **Soil Use and Management**, v. 18, p. 284-292, 2002.

STENBERG, B. Effects of Soil Sample Pretreatments and Standardised Rewetting as Interacted with Sand Classes on Vis-NIR Predictions of Clay and Soil Organic Carbon. **Geoderma**, v. 158, n. 1-2, p. 15-22, ago. 2010.

STENBERG, B.; VISCARRA ROSSEL, R.A.; MOUAZEN, A.M.; WETTERLIND, J. Visible and Near Infrared Spectroscopy in Soil Science. In: **Advances in Agronomy**. Elsevier: Amsterdam, The Netherlands, 2010; Volume 107.

TERRA, F. S.; DEMATTÊ, J. A. M.; VISCARRA ROSSEL, R. A. Proximal Spectral Sensing in Pedological Assessments: Vis-NIR Spectra for Soil Classification Based on Weathering and Pedogenesis. **Geoderma**, v. 318, 2018.

VELLIANGIRI, S.; ALAGUMUTHUKRISHNAN, S.; THANKUMAR J. S. I. A Review of Dimensionality Reduction Techniques for Efficient Computation. **Procedia Computer Science**, v. 165, p. 104-111, 2019.

VISCARRA ROSSEL, R. A. et al. Visible, Near Infrared, Mid Infrared or Combined Diffuse Reflectance Spectroscopy for Simultaneous Assessment of Various Soil Properties. **Geoderma**, v. 131, n. 1-2, p. 59-75, mar. 2006.

WANG, Y.-P. et al. Effect of Wetting on the Determination of Soil Organic Matter Content Using Visible and Near-Infrared Spectrometer. **Geoderma**, v. 376, p. 114528, out. 2020.

WEI, M. C. F.; CANAL FILHO, R.; TAVARES, T. R.; MOLIN, J. P.; VIEIRA, A. M. C. Dimensionality Reduction Statistical Models for Soil Attribute Prediction Based on Raw Spectral Data. **AI**, v. 3, n. 4, p. 809-819, 2022.

WEIL, R.R.; BRADY, N.C. The Nature and Properties of Soils. 15th Edition, Pearson, New York, 2017.

WIJEWARDANE, N. K.; GE, Y.; MORGAN, C. L. S. Moisture Insensitive Prediction of Soil Properties from VNIR Reflectance Spectra Based on External Parameter Orthogonalization. **Geoderma**, v. 267, p. 92-101, abr. 2016.

MICROVARIABILIDADE TEMPORAL DA PRECIPITAÇÃO NO CERRADO DO MATO GROSSO: UMA ABORDAGEM COM DADOS CHIRPS

Renan Francisco Rimoldi Tavanti [1]; João Guilherme Faccin [2]; Lucas Felix [3]
[1]Coordenador de Agricultura Digital. Av. Dr. Nilo Peçanha, 2900 - Petrópolis, Porto Alegre - RS, 91330-001. SLC Agrícola; [2]Cientista de Dados. Av. Dr. Nilo Peçanha, 2900 - Petrópolis, Porto Alegre - RS, 91330-001. SLC Agrícola; [3]Especialista de Planejamento Agrícola. Av. Dr. Nilo Peçanha, 2900 - Petrópolis, Porto Alegre - RS, 91330-001. SLC Agrícola

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
As mudanças climáticas têm impactos significativos na agricultura e em outros setores, tornando crucial compreender a dinâmica da precipitação para o planejamento e gestão de recursos. Esse estudo teve por objetivo avaliar as mudanças temporais de precipitação em microescala ao longo de 822 dias na região do Cerrado do Mato Grosso. Além disso, buscou-se comparar a acurácia do modelo CHIRPS (Climate Hazards Group InfraRed Precipitation) na estimativa da precipitação nessa região específica. Os resultados revelam uma considerável variabilidade na precipitação, com o modelo CHIRPS apresentando diferenças notáveis em relação aos dados observados. A análise comparativa da acurácia do CHIRPS mostra suas limitações, particularmente em escalas temporais menores, onde houve uma tendência de superestimação dos valores de precipitação. A confiabilidade do modelo CHIRPS foi maior para as estimativas de precipitação em escalas temporais mensal e trimestral. Os resultados desse estudo destacam a importância de considerar as incertezas associadas aos modelos de estimativa de precipitação ao planejar e gerenciar recursos em cenários de mudanças climáticas. No contexto mais amplo das alterações climáticas, este estudo destaca a importância contínua da pesquisa e desenvolvimento de modelos climáticos precisos e confiáveis, principalmente para atendimento de regiões ou países em desenvolvimento que muitas vezes carecem de uma rede adequada de estações pluviométricas.

PALAVRAS-CHAVE: Sensoriamento remoto; modelos climáticos em grade; estações meteorológicas

ABSTRACT
Climate change has significant impacts on agriculture and other sectors, making it crucial to understand precipitation dynamics for resource planning and management. This study aimed to evaluate the temporal changes in precipitation at a microscale over 822 days in the Cerrado region of Mato Grosso. Additionally, we sought to compare the accuracy of the CHIRPS (Climate Hazards Group InfraRed Precipitation) model in estimating precipitation in this specific region. The results reveal considerable variability in precipitation, with the CHIRPS model showing notable differences compared to observed data. Comparative analysis of CHIRPS accuracy shows its limitations, particularly at smaller temporal scales, where there was a tendency to overestimate precipitation values. The reliability of the CHIRPS model was higher for precipitation estimates at monthly and quarterly temporal scales. The results of this study highlight the importance of considering the uncertainties associated with precipitation estimation models when planning and managing resources in scenarios of climate change. In the broader context of climate change, this study underscores the ongoing importance of research and development of accurate and reliable climate models, especially to serve regions or countries in development that often lack an adequate network of rain gauge stations.

KEYWORDS: ;

INTRODUÇÃO

As alterações climáticas têm se tornado cada vez mais frequentes, exercendo um impacto direto em diversos setores da sociedade civil, com a agricultura sendo um dos mais afetados. Essas mudanças climáticas resultam em uma variabilidade no clima que modifica não apenas a frequência, mas também a extensão, intensidade e duração de extremos climáticos, levando a eventos sem precedentes (Ebert et al., 2007). Regiões que anteriormente desfrutavam de estabilidade climática agora enfrentam alterações significativas, como veranicos prolongados ou excesso de chuvas, desafiando assim a resiliência dos sistemas de produção agrícola.

A avaliação da variabilidade espaço-temporal da precipitação desempenha um papel crucial no monitoramento de secas e cheias, além de contribuir para uma compreensão mais profunda da dinâmica da precipitação. No entanto, essa avaliação enfrenta desafios, especialmente em países em desenvolvimento que muitas vezes carecem de uma rede adequada de estações pluviométricas. Nesse contexto, o uso de dados de sensoriamento remoto surge como uma ferramenta promissora, pois permite avaliações precisas da precipitação em áreas onde as medições diretas são escassas. Dados de precipitação infravermelha provenientes do Climate Hazards Group (CHIRPS - *Climate Hazards Group InfraRed Precipitation*) têm ganhado destaque, como um dos modelos climáticos em grade disponíveis, fornecendo informações sobre precipitação desde 1981 em uma resolução espacial muito alta (Funk et al., 2015). Esses dados mostram-se particularmente valiosos para avaliar a variabilidade da precipitação em áreas remotas que não foram previamente avaliadas. Embora estudos tenham avaliado o desempenho do CHIRPS em escalas macro, evidenciando sua eficácia (Duan et al., 2016), há uma lacuna na análise em microescala, especialmente em regiões como o Cerrado do Mato Grosso

OBJETIVOS

Diante desse contexto, o objetivo deste estudo é preencher essa lacuna, avaliando as mudanças temporais de precipitação em microescala ao longo de 822 dias na região do Cerrado do Mato Grosso. Além disso, busca-se comparar a acurácia do modelo CHIRPS na estimativa da precipitação nessa região específica. Ao fazer isso, esperamos contribuir para um melhor entendimento das ferramentas digitais disponíveis para entender as dinâmicas climáticas e fornecer insights valiosos para o planejamento e a gestão de recursos diante de cenários de mudanças climáticas

MATERIAL E MÉTODOS

O estudo baseou-se na análise de dados provenientes da Fazenda Paiaguás, pertencente à SLC Agrícola, uma propriedade dedicada à produção comercial de grãos e fibras, situada em Diamantino, Estado de Mato Grosso, com coordenadas geográficas de 14° 4' 43,82" S e 57° 27' 15,81" O, a uma altitude de 623 metros. O clima local é classificado como Aw, segundo a classificação de Köppen, caracterizado por ser tropical úmido, com um verão chuvoso e um inverno seco. As médias anuais de temperatura e precipitação nessa região variam entre 24 e 26 °C e 1.800 e 2.200 mm, respectivamente.

Para a obtenção de dados de precipitação diária, foram utilizadas 69 estações meteorológicas digitais, distribuídas estrategicamente em uma área de 36.000 ha (área total da fazenda), sendo posicionada uma estação para cada 500 hectares (Figura 1). Essas estações são equipadas com sensores de temperatura, umidade e precipitação, que registram informações a cada hora. Os dados são armazenados em nuvem e transmitidos via rede LoRa. O período de análise compreendeu de 01/10/2021 a 31/12/2023, totalizando 822 dias. Os valores médios diários de precipitação (mm/dia) foram calculados pela soma dos valores registrados por todas as estações e divididos pelo total de estações.

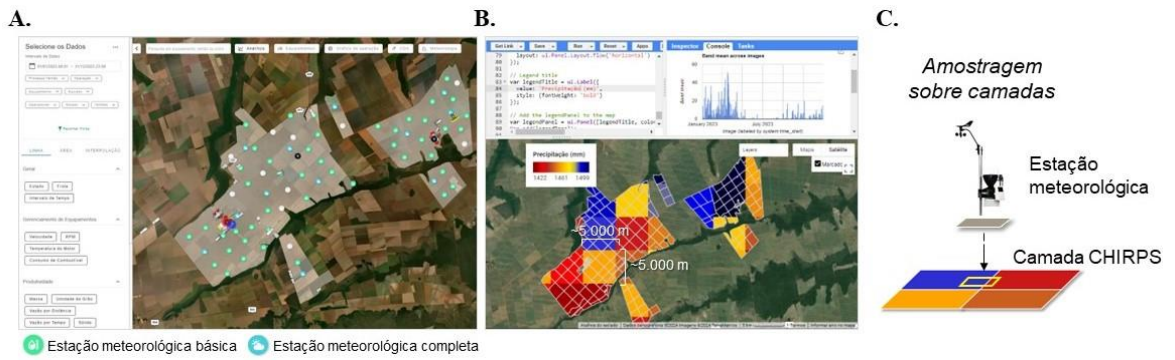


Figura1

FIGURA 1. Delimitação da Fazenda Paiaguás e geolocalização das estações meteorológicas (A). Exemplo de output gerado no Google Earth Engine para camada de precipitação acumulada no período de um ano (B). Esquema de amostragem de valores utilizando a geolocalização das estações meteorológicas sobre a camada CHIRPS.

Adicionalmente, dados de precipitação do modelo CHIRPS foram obtidos através da plataforma de análise geoespacial Google Earth Engine (GEE). O modelo CHIRPS oferece dados com resolução espacial de 0,05 graus decimais (~5.000 metros próximo à linha do Equador) desde 1981 até os dias atuais, disponibilizando conjuntos de dados diários, pentadais e mensais. Este modelo é baseado em medições de satélite e in-situ, desenvolvido pelo U.S Geological Survey (USGS) e pelo Climate Hazards Group, com cobertura quase global (50°S-50°N, 180°E-180°O). O algoritmo CHIRPS combina estimativas de precipitação de Cold Cloud Duration (CCD) e Tropical Precipitation Measuring Mission (TRMM), utilizando dados de precipitação local para calibrar as estimativas.

Um código foi desenvolvido na plataforma GEE para obter os dados diários de precipitação em uma grade que considerava a área delimitada da fazenda Paiaguás. Os valores médios diários de precipitação (mm/dia) foram calculados pela soma dos valores registrados nos pixels do mapa e divididos pela área física total da fazenda. Posteriormente, os dados foram organizados em médias diárias, decendiais, mensais e trimestrais para análises em escalas temporais e espaciais. Após a organização, realizou-se uma análise exploratória e o teste de normalidade de Shapiro-Wilk. Para avaliar as precipitações observadas e estimadas pelo modelo CHIRPS, foram calculados sete métricas estatísticas comumente usadas: coeficientes de determinação (R^2) e correlação (r), viés relativo (BIAS), erro médio absoluto (MAE) e raiz do erro quadrático médio (RMSE). Além disso, foram consideradas métricas de contingência: probabilidade de detecção (POD) e taxa de falsos alarmes (FAR). A POD descreve a fração dos eventos de precipitação observados e detectados corretamente pelo modelo, enquanto a FAR descreve a fração de eventos detectados pelo modelo, mas não observados. As análises estatísticas descritivas e de desempenho do modelo foram realizadas no ambiente R versão 4.2.0 (R CORE TEAM, 2023), utilizando os pacotes "stats" e "Metrics".

RESULTADOS E DISCUSSÃO

Os resultados da análise descritiva revelaram valores médios aproximados de precipitação observada (3,05 mm/dia) e estimada (4,30 mm/dia) pelo modelo CHIRPS na escala diária (Tabela 1). No entanto, houve uma considerável variabilidade, com um desvio padrão de 8,04 mm/dia, que foi 15% maior em comparação à variabilidade da precipitação observada. À medida que aumentamos as escalas de tempo, as diferenças nos volumes médios de precipitação se tornam mais evidentes, chegando a 122 mm na escala trimestral. Isso sugere um efeito de acumulação dos erros de estimativas de precipitação no curto e médio prazo.

Semelhantemente à escala diária, os desvios padrão foram mais altos para as precipitações estimadas pelo modelo CHIRPS em escalas decendial, mensal e trimestral, indicando uma possível tendência de superestimação dos valores de precipitação (Tabela 1). Os valores máximos observados para as estimativas de precipitação corroboraram essa observação.

TABELA 1. Análise descritiva da precipitação observada e estimada pelo modelo CHIRPS em diferentes escalas de tempo.[1]

Variável	Média	Mediana	Mínimo	Máximo	DP	SW
			Diário (mm/dia)			
Observado	3,05	0,05	0,00	62,95	6,85	0,51**
CHIRPS	4,30	0,00	0,00	54,35	8,04	0,60**
			Decendial (mm/decêndio)			
Observado	32,59	13,91	0,00	165,46	39,03	0,82**
CHIRPS	45,98	27,99	0,00	250,64	52,15	0,82**
			Mensal (mm/mês)			
Observado	99,40	54,15	0,14	345,93	107,39	0,85**
CHIRPS	140,19	85,36	0,00	449,93	136,84	0,87**
			Trimestral (mm/trimestre)			
Observado	298,19	242,58	20,80	726,92	265,94	0,86ns
CHIRPS	420,58	243,38	61,41	1077,85	396,26	0,85ns

[1] DP: desvio padrão; SW: valor W obtido no teste de Shapiro-Wilk; * significativo a 5% de probabilidade; ns não significativo.

Gráficos de dispersão foram construídos para visualizar as relações entre os dados observados e estimados em todos os níveis de escala temporal propostos (Figura 2). Observou-se que quanto menor a escala de tempo (decendial e diária), maior a dispersão entre os valores observados e estimados pelo modelo CHIRPS. Os valores de R^2 para as escalas diária e decendial foram classificados como fracos (< 0,30) e moderados (< 0,50), respectivamente. Da mesma forma, o coeficiente de correlação indicou uma relação fraca (> 0,20 e < 0,40) e moderada (> 0,40 e < 0,60), respectivamente (Tabela 2). No gráfico de frequência diária da precipitação, foi possível identificar os dias e períodos em que as inconsistências ocorreram (Figura 2A). A linha de acumulação da precipitação CHIRPS nos períodos de início (setembro/outubro) e fim (abril/maio) das estações chuvosas diferiu da linha de acumulação da precipitação observada, indicando uma maior imprecisão nas estimativas da precipitação diária durante esses meses.

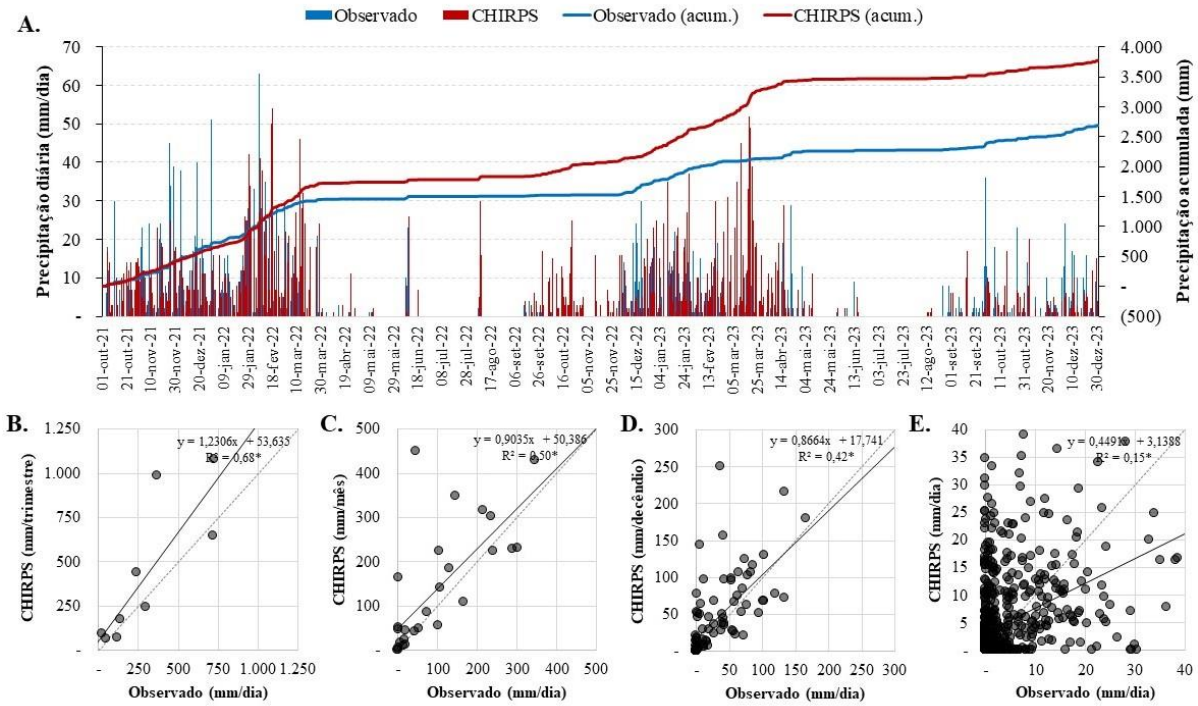


Figura2

FIGURA 2. Frequência diária e acumulada de precipitação observada e estimada pelo modelo CHIRPS (A), e gráficos de dispersão entre valores observados e estimados em escalas trimestral (B), mensal (C), decendial (D) e diária (E).

Ao analisar as métricas que avaliam a contingência das estimativas CHIRPS, observou-se que as precipitações em escalas diária e decendial apresentaram valores distintos de POD, 0,51 e 0,99, respectivamente (Tabela 2). Isso sugere que as estimativas de eventos decendiais ocorreram de forma satisfatória, indicando "verdadeiros positivos". Por outro lado, os valores de FAR foram de 0,49 e 0,01, respectivamente, indicando uma alta ocorrência de "falsos positivos" para estimativas de precipitação diária.

TABELA 2. Resumo das métricas estatísticas de precipitação utilizando dados estimados pelo modelo CHIRPS em diferentes escalas de tempo.[1]

Escala	R^2	r	MAE	RMSE	POD	FAR
Diário	0,155	0,394	4,014	8,346	0,507	0,493
Decendial	0,420	0,648	24,502	41,989	0,988	0,012
Mensal	0,503	0,709	60,907	103,602	0,963	0,037
Trimestral	0,682	0,826	162,873	250,393	1,000	0,000

[1] R^2: coeficiente de determinação; r: coeficiente de correlação; BIAS: viés relativo; MAE: erro médio absoluto; RMSE: raiz do erro quadrático médio; POD: probabilidade de detecção; FAR: taxa de falsos alarmes.

A confiabilidade do modelo CHIRPS foi maior para as estimativas de precipitação em escalas mensal e trimestral (Tabela 2). Os valores de R^2 foram de 0,50 e 0,68, respectivamente, ambos classificados como uma forte relação entre os dados observados e estimados. Da mesma forma, observou-se uma forte correlação (r > 0,70). A precisão das estimativas foi satisfatória, com MAE de 60,90 e 162,87,

e RMSE de 103,60 e 250,39, para as escalas mensal e trimestral, respectivamente. Com base nos gráficos de dispersão, os pontos e a linha de tendência aproximaram-se da linha de referência 1:1, confirmando as métricas observadas. As métricas de contingência das estimativas CHIRPS para essas escalas foram semelhantes às discutidas anteriormente para a escala decendial, com valores de POD acima de 0,90 e FAR próximo de zero.

As limitações do modelo CHIRPS foram evidenciadas ao analisar as estimativas diárias de precipitação, onde o modelo tendeu a prever precipitações em dias sem registros de ocorrências (Figura 2A e 2E). Exemplos específicos ocorreram em períodos de início das estações chuvosas (27/09/2022 a 16/10/2022) e veranicos (05/11/2022 a 25/11/2022). É importante considerar que os anos de 2021, 2022 e 2023 foram marcados por intensas oscilações de fenômenos de interação atmosfera-oceano, caracterizando 2021 e 2022 como La Niña de intensidade moderada e 2023 como El Niño de intensidade forte, dificultando as estimativas de precipitação pelos modelos existentes. Esse problema decorre de vários fatores, incluindo as técnicas utilizadas para a estimativa de precipitação baseada em satélite, como a relação estabelecida entre leituras espectrais (como infravermelho e micro-ondas) com a temperatura do topo das nuvens e a precipitação, bem como a área geográfica para a qual o modelo foi treinado, dificultando o mapeamento de eventos extremos e mudanças climáticas.

Em resumo, os resultados apresentados destacam a necessidade contínua de avaliação e aprimoramento dos modelos de estimativas de precipitação, especialmente em áreas propensas a oscilações climáticas significativas, a fim de fornecer informações meteorológicas mais precisas e confiáveis para tomadas de decisão.

CONCLUSÃO

Ao longo de 822 dias constatou-se considerável variabilidade temporal da precipitação, com diferenças acentuadas entre os meses de início (setembro/outubro) e fim (abril/maio) da estação de chuvas.

As limitações do modelo CHIRPS foram evidenciadas ao analisar as estimativas diárias de precipitação, onde o modelo tendeu a superestimar ou prever precipitações em dias sem registros de ocorrências.

As estimativas de precipitação utilizando o modelo CHIRPS são satisfatórias para aferir precipitações em escalas mensal e trimestral em anos de ocorrência de ENOS.

No contexto mais amplo das alterações climáticas em curso, este estudo contribui para um melhor entendimento das dinâmicas climáticas na região do Cerrado do Mato Grosso e destaca a necessidade contínua de pesquisa e desenvolvimento de modelos climáticos mais precisos e confiáveis. Espera-se que esses esforços ajudem a fortalecer a resiliência dos sistemas de produção agrícola e a promover uma gestão mais sustentável dos recursos naturais diante dos desafios climáticos emergentes.

REFERÊNCIAS

DUAN, Z.; LIU, J.; TUO, Y.; CHIOGNA, G.; DISSE, M. Evaluation of eight high spatial resolution gridded precipitation products in Adige Basin (Italy) at multiple temporal and spatial scales. **Science of the Total Environment**, v.573, p.1536-1553, 2016.

EBERT, E.E.; JANOWIAK, J.E.; KIDD, C. Comparison of near-real-time precipitation estimates from satellite observations and numerical models. **Bulletin of the American Meteorological Society**, v.88, p.47, 2007.

FUNK, C.; PETERSON, P.; LANDSFELD, M.; PEDREROS, D.; VERDIN, J.; SHUKLA, S.; HUSAK, G.; ROWLAND, J.; HARRISON, L.; HOELL, A.; MICHAELSEN, J. The climate hazards infrared precipitation with stations - a new environmental record for monitoring extremes. **Scientific Data**, v.8, n.2, p.1-21, 2015.

R CORE TEAM. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. 2023. URL: https://www.R-project.org/

DETECÇÃO PRECOCE DE ATAQUE DE NEMATOIDE POR TERMOGRAFIA INFRAVERMELHA EM CULTURA DE ALGODÃO

LETÍCIA PIAZENTIN DANTAS [1]; BIANCA BATISTA BARRETO [3]; OTÁVIO RODRIGUES DE PAULA [1]; JOÃO VICTOR SILVA VIANA [1]; DÉBORA,M. B. P. MILORI [2]

[1]Bolsista . Rua XV de novembro, 1452 - Centro, São Carlos - SP. Empresa Brasileira de Pesquisa Agropecuária; [2]Pesquisador. Rua XV de novembro, 1452 - Centro, São Carlos - SP. Empresa Brasileira de Pesquisa Agropecuária; [3]Pós Doutorado. Rua XV de novembro, 1452 - Centro, São Carlos - SP. Empresa Brasileira de Pesquisa Agropecuária

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Com o aumento da produção de algodão no Brasil, tem-se observado um crescimento significativo de doenças, incluindo aquelas causadas por patógenos do solo e manchas foliares, resultando em prejuízos consideráveis na produção. O nematoide Aphelenchoides besseyi, um dos principais patógenos do algodão, ganhou destaque por afetar também a cultura da soja, conhecida como Soja Louca II, resultando em danos irreversíveis à produção. Uma possível solução é o uso de técnicas de imagens térmicas para identificar estresses causados pelo patógeno nas plantas. As imagens termográficas registram a radiação infravermelha dos corpos, mapeando as temperaturas do dossel para avaliar estresses hídricos e detectar doenças. Diante desse cenário, o objetivo deste trabalho foi utilizar termografia infravermelha para detectar precocemente o ataque de nematoide na cultura do algodão em casa de vegetação. O experimento foi conduzido em uma casa de vegetação, onde foram criadas condições controladas com plantas saudáveis e plantas inoculadas com o nematoide. Foram utilizados algoritmos de machine learning para gerar os modelos de classificação. Os resultados demonstram que a técnica de imagem termográficas foi capaz de distinguir entre as plantas saudáveis e as infectadas pelo patógeno com taxa de acerto de 90%.

PALAVRAS-CHAVE: Termografia Infravermelha; Detecção precoce; patógeno

ABSTRACT

As cotton production in Brazil rises, a significant growth in diseases has been observed, including those caused by soil pathogens and foliar spots, resulting in considerable losses in production. The nematode Aphelenchoides besseyi, one of the main cotton pathogens, has gained prominence for also affecting soybean cultivation, known as Crazy Soybean II, resulting in irreversible damage to production. One possible solution is the use of thermal imaging techniques to identify stresses caused by the pathogen in plants. Thermal images record the infrared radiation from bodies, mapping canopy temperatures to assess water stress and detect diseases. Given this scenario, the objective of this study was to use infrared thermography to detect early nematode infestation in cotton cultivation in a greenhouse. The experiment was conducted in a greenhouse, where controlled conditions were created with healthy plants and plants inoculated with the nematode. Machine learning algorithms were used to generate classification models. The results demonstrate that thermal imaging techniques were able to distinguish between healthy plants and those infected by the pathogen with an accuracy rate of 90%..

KEYWORDS: ;

INTRODUÇÃO

O crescimento do Agronegócio brasileiro é impulsionado pela adoção de tecnologias avançadas e investimentos em pesquisa, elevando a produtividade sem necessidade de aumentar a área cultivada, consolidando o país como uma potência na produção de commodities agrícolas (revista exame). Atualmente, o Brasil é um dos principais produtores e exportadores de algodão e soja, com produções de 140 milhões de toneladas de soja e 2,82 milhões de toneladas de pluma de algodão na safra 2021/2022 (EMBRAPA, 2022). No entanto, o aumento da produtividade agrícola também trouxe desafios, como o surgimento da Soja Louca II, causada pelo nematoide *Aphelenchoides*, identificado em 2015. Esse patógeno, também encontrado no algodoeiro, resultou em perdas significativas na produção, evidenciando a necessidade de medidas de controle eficazes para evitar prejuízos econômicos, que podem chegar a 100%. (MEYER et. al. 2017). O nematoide *Aphelenchoides besseyi* provoca várias alterações morfológicas e fisiológicas nas plantas, como clorose, enrugamento de folhas, perda de botões florais e engrossamento de nós.(GALBIERI, 2021). Devido à recente identificação da doença no algodão e soja, não há métodos eficazes de controle ou detecção precoce do *A. besseyi*. Uma possível solução é o uso de técnicas de imagens térmicas para identificar estresses causados pelo patógeno nas plantas. As imagens termográficas registram a radiação infravermelha dos corpos, mapeando as temperaturas do dossel para avaliar estresses hídricos e detectar doenças. Estudos têm empregado a termografia para avaliar genótipos de plantas em relação à tolerância à seca e salinidade (Sirault et al., 2009), bem como para determinar o estado hídrico das plantas (Bian et al., 2019). Assim, o objetivo deste trabalho é de utilizar termografia infravermelha para detectar precocemente o ataque de nematoide na cultura do algodão em casa de vegetação.

OBJETIVOS

O objetivo deste trabalho é de utilizar termografia infravermelha para detectar precocemente o ataque de nematoide na cultura do algodão em casa de vegetação.

MATERIAL E MÉTODOS

Os experimentos foram realizados em uma casa de vegetação com ambiente controlado, mantendo a temperatura do ar a 30°C e a umidade relativa do ar a 80%. As sementes de algodão da cultivar IMA 5801B2RF, Campo 2OP Safra 2019/20, foram fornecidas pelo IMA Instituto Mato-Grossense do Algodão e cultivadas em vasos de 650 ml com substrato, duas sementes por vaso. A inoculação do nematoide foi feita oito dias após a semeadura, utilizando uma solução contendo 500 nematoides por planta. A solução, preparada para aplicação de 600 µl, foi distribuída, sendo um terço na parte aérea da planta e dois terços na região inferior, próximo ao caule, raiz e solo (Figura 1a). Após a inoculação, foi aguardado 48 horas para o início com as medições. O monitoramento foi realizado em um período de 21 dias, totalizando 10 tempos. As medições foram sempre nos mesmos horários e na mesma sequência. Foram utilizados 8 vasos testemunhas e 8 vasos inoculados por tempo, totalizando 160 amostras (Figura 1b).

FIGURA 1. (a) inoculação de nematoides e (b) condução do experimento em casa de vegetação.



FIGURA 1. (a) inoculação de nematoides



(b) condução do experimento em casa de vegetação

A medição termográfica foi conduzida na casa de vegetação, onde uma câmera termográfica da marca FLIR, modelo T-420, montada em um tripé, permaneceu em posição fixa. Duas imagens térmicas (Figura 2) foram capturadas diariamente, uma com uma bandeja contendo quatro amostras testemunhas e outra com quatro amostras inoculadas. As capturas de imagem iniciavam-se às 8h30, com o tripé e as amostras posicionados de forma consistente com marcações no chão da casa de vegetação. A distância da câmera ao solo era de 1m, com parâmetros como temperatura, umidade relativa do ambiente e emissividade da planta (0,96) sendo constantemente monitorados para garantir a padronização dos dados. Os dados de temperatura e umidade foram registrados por um termo-higrômetro da marca Prolab. Após adicionar essas informações, a imagem é focalizada e capturada manualmente.

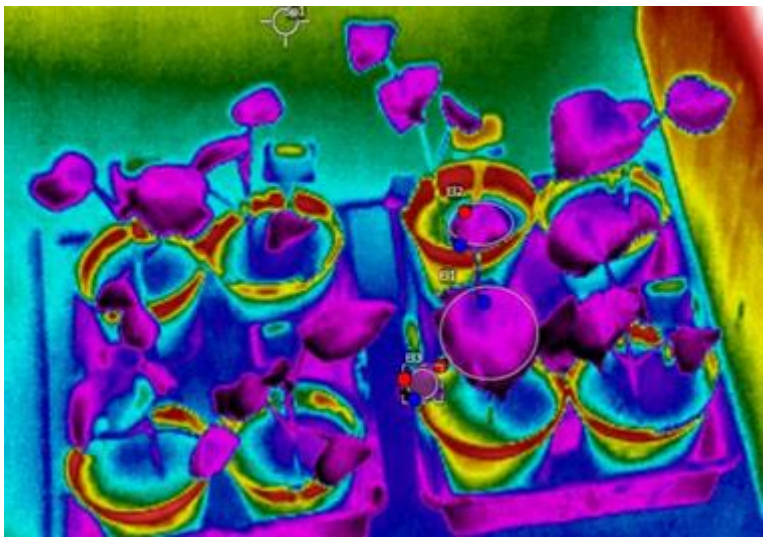


FIGURA 2. Imagem da termografia infravermelha.

FIGURA 2. Imagem da termografia infravermelha.

Os dados das imagens termográficas foram retirados pelo programa Thermal Studio, desta forma, foram desenvolvidas planilhas onde constavam as temperaturas mínimas, médias e máximas de cada área em estudo. A manipulação e visualização dos dados, bem como a implementação do modelo, foram realizadas em Python, utilizando as bibliotecas numpy e pandas. Para o processamento dos dados e a implementação dos modelos de classificação, foi utilizada a biblioteca scikit-learn. O Google Colab foi o editor principal utilizado para escrever os códigos. A determinação do algoritmo de aprendizado de máquina, no qual, é um conjunto de regras e procedimentos matemáticos que permite que um sistema computacional aprenda padrões e faça previsões a partir de dados. Seguiu as seguintes etapas: a seleção do Modelo, onde escolherá um modelo de aprendizado de máquina adequado para o problema; treinamento do Modelo, no qual o modelo será treinado utilizando os dados coletados, para o ajuste de parâmetros para minimizar o erro entre as previsões do modelo; avaliação do Modelo, onde modelo será avaliado utilizando dados de teste ou validação, que não foram usados durante o treinamento, verificando se o modelo será capaz de generalizar para novos dados e fazer previsões precisas; ajuste e otimização, se necessário, o modelo pode ser ajustado e otimizado com base nos resultados da avaliação; por último, a implantação e uso: o modelo treinado e validado.

RESULTADOS E DISCUSSÃO

Foram geradas 20 imagens termográficas, contendo quatro plantas sadias e quatro plantas inoculadas com nematoides em cada imagem Os parâmetros utilizados foram a temperatura máxima, média e mínima de cada planta, resultando em 160 amostras com 3 parâmetros cada. O algoritmo adotado foi o AdaBoost, uma técnica de aprendizado de máquina projetada para aprimorar o desempenho de modelos de classificação, atribuindo maior peso às instâncias classificadas de forma incorreta. Durante o processo de treinamento, cada iteração subsequente enfatiza as instâncias classificadas erroneamente, direcionando o próximo modelo a focar mais nesses casos. Isso capacita o AdaBoost a lidar com as instâncias mais desafiadoras de classificar, aprimorando progressivamente a precisão do modelo final. Foi realizado uma calibração do modelo usando 75% das amostras (treino) e o validação externa do modelo usando 25% das amostras (teste). Com os atributos padronizados e utilizando o modelo de aprendizado de máquina adaboost, foi possível a comparação das temperaturas das amostras sadias com as temperaturas das plantas inoculadas, assim, conseguiu-se uma taxa de acerto de 90% nas amostras de teste. A Figura 3a, mostra a matriz a média das classes testemunha (azul) e inoculada (vermelho). Já matriz de confusão com o valor da taxa de acerto das amostras testes (Figura 3b), observa-se que o algoritmo classifica corretamente 18 amostras verdadeiro negativo (0,0)

como testemunha, 2 amostras classificadas incorretamente como inoculadas (0,1), classifica certamente 18 amostras inoculadas (1,1) e apenas 2 inoculada como sadia, falso negativo (1,0).

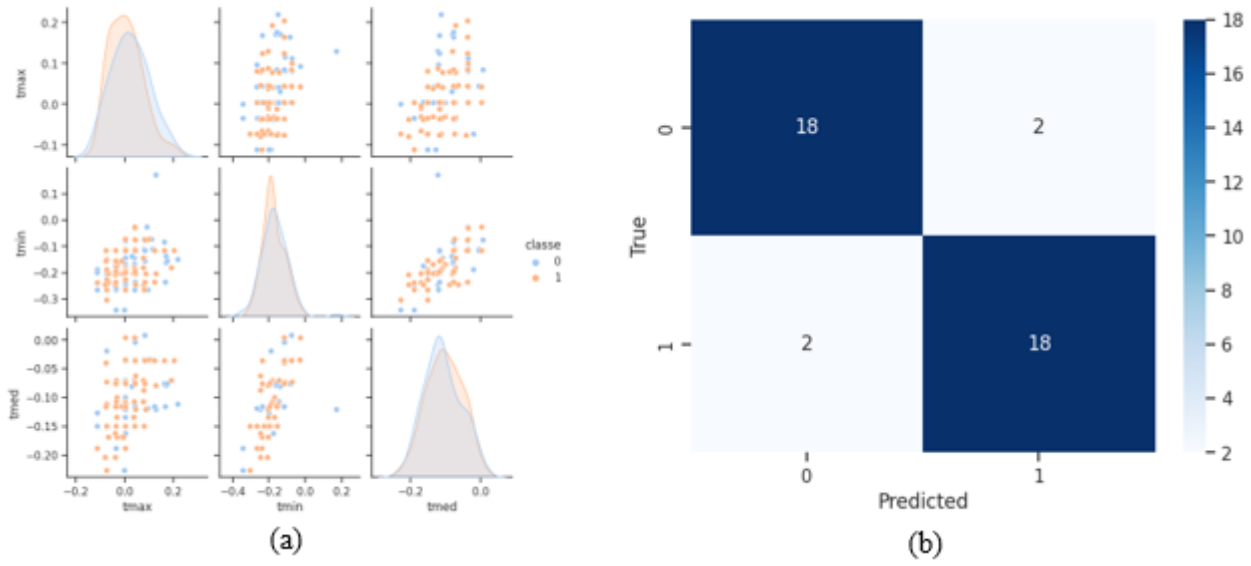


FIGURA 3. (a) gráfico das médias e (b) matriz de confusão

A imagem termográfica obteve bom desempenho, tornando-se uma técnica promissora. As plantas inoculadas apresentaram temperatura do dossel superior do que as plantas sadias, indicando que, as plantas quando sofrem ataque do nematoide Aphelenchoides besseyi tendem a fechar os estômatos, como mecanismo de defesa da planta, dificultando as trocas gasosas e ocasionando o aumento de temperatura da planta. É possível prever que o algodão acometido por outros patógenos apresentariam temperaturas divergentes a plantas saudáveis, visto que a resposta de defesa da planta pode aumentar sua atividade metabólica, elevando a temperatura.

CONCLUSÃO

Com este trabalho concluiu-se que a imagem de fluorescência é uma técnica eficaz para identificar precocemente o ataque de A. besseyi na cultura do algodão em ambiente controlado, permitindo detecção até três dias antes dos sintomas visuais aparecerem. Entretanto, são necessários mais experimentos e aprimoramentos na análise de dados para diminuir o tempo de detecção e avaliar a capacidade da técnica em distinguir outros tipos de estresses. Além de testes em outras culturas e patógenos.

AGRADECIMENTOS

Este trabalho foi financiado pela Embrapa Instrumentação, CAPES, CNPq, FAPESP, COMDEAGRO e IMA.

REFERÊNCIAS

MEYER, M. C.; FAVORETO, L.; KLEPKER, D.; MARCELINO-GUIMARÃES, F. C. Soybean green stem and foliar retention syndrome caused by Aphelenchoides besseyi. Tropical Plant Pathology, v. 42, n. 5, p. 403-409, 2017. DOI: https://doi.org/ 10.1007/s40858-017-0167-z.

GALBIERI R., "Aphelenchoides besseyi no algodoeiro," XI Encontro Técnico Algodão Fundação Mato Grosso Integração: A chave que abre nossos horizontes (2021).

SIRAULT, X. R. R.; JAMES, R. A.; FURBANK, R. T. A new screening method for osmotic component of salinity tolerance in cereals using infrared thermography. Functional Plant Biology, v. 36, n. 11, p. 970-977, 2009.

BIAN, J.; ZHANG, Z.; CHEN, J.; CHEN, H.; CUI, C.; LI, X.; CHEN. S.; FU, Q. Simplified evaluation of cotton water stress using high resolution unmanned aerial vehicle thermal imagery. Remote Sensing, v. 11, n. 3, e267, 2019. DOI: 10.3390/rs11030267.

PRODUTIVIDADE DA CULTURA DA SOJA E OS ÍNDICES DE VEGETAÇÃO

Luiz Gustavo Kern [1]; Marcelo Silveira de Farias [2]; José Cardoso sobrinho [3]; Luciano Zucuni Pes [4]; Ivan Carlos Maldaner [5]

[1]Bolsista. Avenida Roraima. UNIVERSIDADE FEDERAL DE SANTA MARIA; [2]Docente. Avenida Roraima. UNIVERSIDADE FEDERAL DE SANTA MARIA; [3]Docente. Avenida Roraima. UNIVERSIDADE FEDERAL DE SANTA MARIA; [4]Docente. Avenida Roraima. UNIVERSIDADE FEDERAL DE SANTA MARIA; [5]Docente. Avenida Roraima. UNIVERSIDADE FEDERAL DE SANTA MARIA

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A aplicação do Sensoriamento Remoto voltado para a previsão de produtividade e manejo da lavoura está ganhando maior destaque na Agricultura de Precisão. O uso de imagens de satélite possibilita monitorar as culturas remotamente e com o apoio do geoprocessamento e da ciência da computação, analisar os dados. Neste sentido, este trabalho teve como objetivo comparar diferentes índices de vegetação e sua correlação com mapas de produtividade para a cultura da soja. As imagens foram obtidas do satélite Sentinel 2, por meio da ferramenta de análise de dados espaciais *Google Earth Engine*. Os dados de produtividade foram gerados a partir de uma colhedora autopropelida de grãos, equipada com sensores de produtividade e sistema GNSS. Após a coleta, foi realizada a correlação dos dados no *software* Rstudio. O NDVI apresentou maior correlação com a produtividade em relação ao NDRE, apresentando 0,48 quando a cultura se encontrava no estádio fenológico R3/R4 e a menor correlação de 0,22 quando a cultura estava no final do ciclo. Quanto ao NDRE a maior correlação foi de 0,29 e a menor de -0,01. Conclui-se que, o NDVI apresentou melhor correlação e significância, entretanto, mesmo com resolução espacial e temporal das imagens cada vez mais avançadas, é necessário considerar mais de uma safra agrícola, bem como estudos sobre efeitos biofísicos e geofísicos da região em estudo.

PALAVRAS-CHAVE: sensoriamento remoto; mapa de produtividade; análise de dados

ABSTRACT

The application of Remote Sensing focused on yield prediction and crop management is gaining greater prominence in Precision Agriculture. The use of satellite imagery allows for remote monitoring of crops and, with the support of geoprocessing and computer science, data analysis. In this context, this study aimed to compare different vegetation indices and their correlation with yield maps. Images were obtained from the Sentinel 2 satellite using the Google Earth Engine spatial data analysis tool. Yield data were collected using a self-propelled grain harvester equipped with yield sensors and GNSS system. Data correlation was performed using Rstudio software. NDVI showed a higher correlation with yield compared to NDRE, with a correlation coefficient of 0.48 on January 30, 2023, when the crop was at the R3/R4 phenological stage, and the lowest correlation of 0.22 on April 20, 2023, at the end of the crop cycle. Regarding NDRE, the highest correlation was 0.29 on February 11, 2023, and the lowest was -0.01 on April 10, 2023. It is concluded that NDVI showed better correlation and significance. However, even with increasingly advanced spatial and temporal resolution of images, it is necessary to consider multiple agricultural seasons, as well as studies on the biophysical and geophysical effects of the study region.

KEYWORDS: remote sensing; productivity map; data analysis

INTRODUÇÃO

A Agricultura de Precisão (AP) vem utilizando diversas fontes de conhecimento para promover a inovação. Dentre as diversas tecnologias em uso, o Sensoriamento Remoto (SR) fornece informações provindas de satélites, que reduzem custos e otimizam o trabalho de monitoramento dos talhões agrícolas. Neste sentido, o SR é definido como a interação da radiação eletromagnética com os alvos terrestres (PONZONI, 2001), representando a capacidade de obter informações do uso da terra de forma remota. Na AP, o SR permite monitorar as culturas agrícolas, quanto ao ataque de pragas e doenças, a necessidade de irrigação, a estimativa da produtividade, dentre outras variáveis.

O SR está voltado para o uso dos índices de vegetação relacionados com práticas de manejo e estimativa da variabilidade da produtividade das culturas agrícolas. Segundo Ponzoni e Shimabukuro (2010), os alvos interagem de maneira diferente, de acordo com as características físico-químicas, onde a absorção de radiação da vegetação é alta, devido à sanidade e ao estádio fenológico das plantas. Assim, o uso de diferentes índices permite avaliar o desempenho da cultura ao longo do ciclo, em diferentes faixas espectrais.

Os estudos realizados na área mostram diferenças nos resultados quando se trabalha com diferentes culturas. No caso da soja, vem sendo realizados, cada vez mais, estudos comparativos visto que, um talhão agrícola pode ter suas propriedades físicas e químicas significativamente alteradas, em relação ao seu vizinho e assim, deve ser levado em consideração vários fatores, como: clima, topografia do terreno e características do solo, para validar o resultado encontrado por meio desses índices de vegetação.

As faixas do espectro eletromagnético fornecem valores de radiância para os estudos do Índice de Vegetação por Diferença Normalizada (NDVI) nos comprimentos de onda do vermelho e infravermelho. No entanto, os comprimentos de onda que estão entre essas faixas podem apresentar variações, e, neste caso, o uso de outros índices, como o Índice de Vegetação de Borda Vermelha por Diferença Normalizada (NDRE), que utiliza o comprimento de onda da borda do vermelho, isto é, faixa espectral que fica entre o vermelho e infravermelho, fornece mais uma informação de radiação, que pode discriminar outras feições dentro do talhão.

Tendo em vista que, uma das premissas da AP é trabalhar para promover a sustentabilidade na agricultura, o uso de práticas de monitoramento remoto, apresentam alternativas que reduzem os impactos ao ambiente, além da aplicação dos recursos de maneira localizada, precisa e otimizada. Portanto, o presente trabalho buscou avaliar os diferentes resultados obtidos por índices de vegetação e a cultura da soja com métodos geoestatísticos.

OBJETIVOS

O objetivo do presente trabalho é comparar diferentes índices de vegetação e sua correlação com mapas de produtividade para a cultura da soja.

MATERIAL E MÉTODOS

O estudo foi conduzido no talhão agrícola denominado "Campo Nativo", localizado na Universidade Federal de Santa Maria (UFSM), *Campus* Sede, sendo um dos talhões agrícolas de culturas anuais de grãos, na área denominada Área Agrícola do Colégio Politécnico, da UFSM (234290S, 6708826N UTM), com área total de 15,09 hectares e altitude de 98 metros acima do nível médio dos mares (Figura 1). O estudo foi realizado com dados obtidos da safra 2022/2023, onde a semeadura foi realizada no dia 24.11.2022 com as cultivares de soja BMX Fibra IPRO, BMX Garra IPRO e BMX Valente RR e a colheita foi realizada na data 25.04.2023. O clima da região é do tipo Cfa - temperado chuvoso e quente, de acordo com Köppen, sendo úmido todo o ano e temperatura entre 2 e 18°C no inverno, e superior a 22°C no verão.

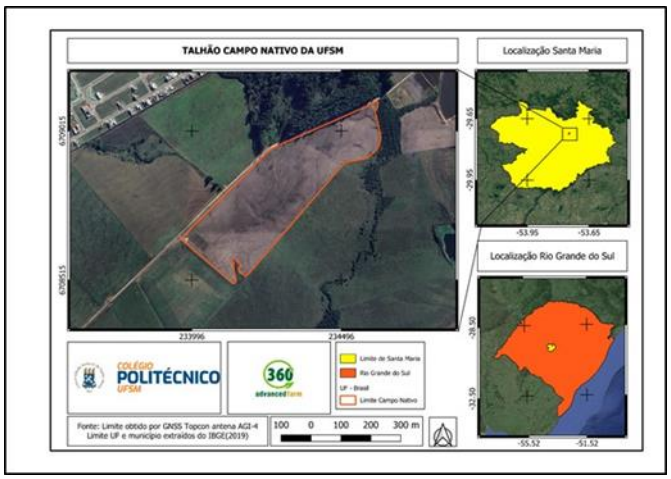


FIGURA 1: Mapa de localização da área de estudo.

A metodologia utilizada consistiu em correlacionar dados de produtividade com os índices NDVI e o NDRE, obtidos de imagens de satélite. Assim, foi possível monitorar e entender a variabilidade espacial e temporal, como o crescimento da vegetação por meio da resposta de biomassa, conforme a evolução da cultura nos seus estádios vegetativos. Os dados da Tabela 1 apresentam as informações extraídas do sensoriamento remoto para realização dos índices de vegetação.

TABELA 1: Bandas espectrais utilizadas para a realização dos índices de vegetação e a equação de cada índice.

BANDAS ESPECTRAIS	ÍNDICE DE VEGETAÇÃO	
	Comprimento de onda central (nm)	Resolução Espectral (m)
Azul	490	10
Verde	560	10
Vermelho (RED)	665	10
Borda do Vermelho (RED_EDGE)	740	20
Infravermelho Próximo (NIR)	842	10
Equação NDVI	(NIR - RED) / (NIR + RED)	
Equação NDRE	(RED-EDGE - RED) / (RED-EDGE + RED)	

Os dados de colheita da cultura da soja, safra 2022/2023, foram extraídos do monitor que armazena os dados de georreferenciamento, obtidos por um receptor GNSS ambos embarcados na colhedora da marca Massey Ferguson, modelo MF 32 Advanced. O sistema medidor da produtividade da máquina foi o *YieldTrakk*®. As imagens de satélite foram obtidas por meio da plataforma *Google Earth Engine* (GEE), que armazena dados espaciais de diversos satélites. A plataforma permite a análise dos índices de vegetação e extração das imagens que foram utilizadas para correlação com dados de produtividade. Já, o mapa de produtividade da área é um componente de AP e representa a variabilidade produtiva e possibilita a criação de áreas de baixa, média e alta produção, possibilitando estratégias para o manejo futuro da área.

A terceira etapa do trabalho foi a análise dos dois conjuntos dados (dados de colheita e de NDVI), sobrepondo as camadas (*layers*), com o objetivo de analisar a variação dos dados de produtividade,

em relação aos índices. Assim, esse procedimento foi realizado com o uso do *software* QGIS e envolveu a aplicação de um *buffer* interno de 10 metros, como forma de segurança para eliminar possíveis pixels com mistura espectral, assim como a reamostragem da banda da borda do vermelho (red-edge) para 10 m.

Fez-se necessário a realização da filtragem dos dados de produtividade, por meio de técnicas da geoestatística, para possibilitar a interpolação dos dados. Neste caso, foi utilizado o método de interpolação por krigagem ordinária, com a finalidade de testar a homogeneidade das variâncias e a inexistência de variáveis auto correlacionadas utilizando o *plugin Smart-Map*. O método de filtragem envolveu, primeiramente, a eliminação manual de valores considerados *outliers* de produtividade abaixo de 600 kg/ha e acima de 6000 kg/ha. Posteriormente, foi realizado o cálculo de amplitude interquartil a partir dos dados de mediana superior e inferior por meio das seguintes equações proposta por Ferreira et al (2022):

IQR = Q3 - Q1

Onde:

IQR = Intervalor interquartil

Q3 = Mediana superior ou quartil 3

Q1 = Mediana inferior ou quartil 1

A eliminação dos outliers a partir da pré-filtragem manual é realizada pela equação proposta pelo autor acima por meio da identificação dos limites superiores e inferiores.

Lsup = valor mediano + (1,5 * IQR)

Linf = valor mediano - (1,5 * IQR)

Onde:

Lsup = Limite superior

Linf = Limite inferior

valor mediano = Mediana para o conjunto de dados

IQR = Limite interquartil

Após a interpolação, foi realizada a correlação por meio do método de Pearson, para analisar a relação entre as duas variáveis de estudo e o seu nível de significância, com o objetivo de verificar se há a possibilidade de prever a produtividade com o uso dos Índices de Vegetação. O teste de significância da correlação dos índices de vegetação com a produtividade foi calculado com base na equação 1.

$$t_0 = r\sqrt{\frac{n-2}{1-r^2}}$$

Onde:

t_0 = Tabela de distribuição *t students*

r = Coeficiente de correlação para a observação

n = Total de observações

Portanto, para a significância foi utilizado a tabela de distribuição de *t-student* para encontrar o grau de liberdade a ser usado na equação. Ao todo, foram utilizadas 22 imagens de diferentes dados totalizando 44 amostras, somando a análise dos Índices NDVI e NDRE, para inserir no cálculo estatístico. Então foi utilizado grau de liberdade como 42, o que para o valor crítico escolhido como 0,05 atribui-se valores de 2,02 como sendo o limite para definir o teste *t-student* acima disso como significante, e abaixo disso como não significante. Este valor, definido como valor crítico e limite de teste t, está descrito na metodologia proposta por Roque (2014?).

RESULTADOS E DISCUSSÃO

O mapa de produtividade resultante é apresentado na Figura 2. A variação de produtividade com os dados filtrados foi inferir a 2.000 kg/ha até pouco mais de 5.000 kg/ha, sendo que os dados brutos foram encontrados variações de 0.9 kg/ha à superior de 50.000 kg/ha. Portanto é evidente a importância de tratar os dados antes de realizar quaisquer estudos, destacando a complexidade na análise e interpretação dos fatores relacionados a tais resultados.

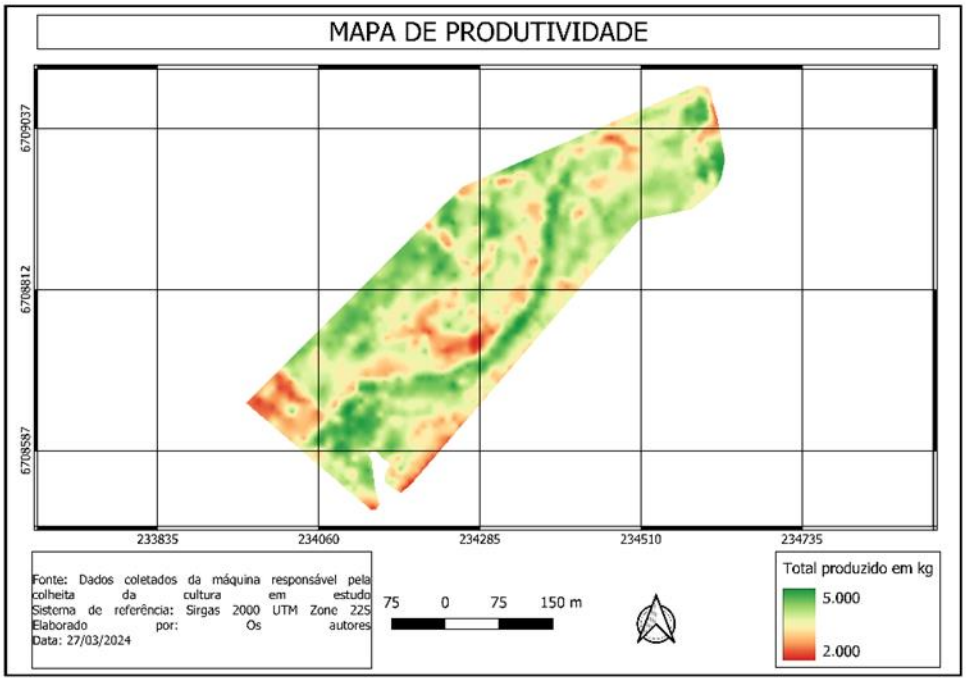


FIGURA 2: Mapa de produtividade de soja do talhão Campo Nativo, pertencente ao Colégio Politécnico da UFSM.

Os resultados obtidos por meio das análises estatísticas mostraram variações na tabela de resultados da correlação de significância para os índices estudados (Tabela 2), ao longo do ciclo de desenvolvimento da cultura da soja. Neste sentido, Molin (2015) destaca que, a Agricultura de Precisão assume a complexidade dos fatos e fatores influentes nas variações que os talhões agrícolas apresentam e que podem corresponder às diferenças de produtividade dentro de um mesmo talhão.

A correlação entre os mapas de produtividade e índices de vegetação é importante no que diz respeito ao uso das técnicas de Sensoriamento Remoto para discutir alternativas como ferramentas e

tecnologias para o desenvolvimento da agricultura. O Sensoriamento Remoto desempenha papel fundamental no que diz respeito ao monitoramento do uso do solo, principalmente a partir das informações contidas nas imagens de satélites que podem servir para diversas aplicações, muito utilizada na agricultura para a extração e análise de índices de vegetação (OLIVEIRA et al., 2012). Portanto, constatou-se que, o uso de técnicas estatísticas é fundamental para verificar a precisão dos dados

TABELA 2: Resultados da correlação e significância para os índices estudados.

Datas 2023	Resultados				
	Índice	Correlação	T-Calculado	T-Tabelado	Significância
05 de janeiro	NDRE	0,12	0,76	2,01	Não significativo
05 de janeiro	NDVI	0,36	2,47	2,01	Significativo
07 de janeiro	NDRE	0,11	0,70	2,01	Não significativo
07 de janeiro	NDVI	0,37	2,54	2,01	Significativo
17 de janeiro	NDRE	0,18	1,15	2,01	Não significativo
17 de janeiro	NDVI	0,40	2,83	2,01	Significativo
20 de janeiro	NDRE	0,21	1,37	2,01	Não significativo
20 de janeiro	NDVI	0,42	3,03	2,01	Significativo
25 de janeiro	NDRE	0,25	1,67	2,01	Não significativo
25 de janeiro	NDVI	0,46	3,32	2,01	Significativo
27 de janeiro	NDRE	0,21	1,38	2,01	Não significativo
27 de janeiro	NDVI	0,41	2,89	2,01	Significativo
30 de janeiro	NDRE	0,24	1,63	2,01	Não significativo
30 de janeiro	NDVI	0,48	3,51	2,01	Significativo
01 de fevereiro	NDRE	0,27	1,83	2,01	Não significativo
01 de fevereiro	NDVI	0,44	3,20	2,01	Significativo
02 de fevereiro	NDRE	0,24	1,63	2,01	Não significativo
02 de fevereiro	NDVI	0,43	3,10	2,01	Significativo
11 de fevereiro	NDRE	0,29	1,97	2,01	Não significativo
11 de fevereiro	NDVI	0,36	2,53	2,01	Significativo
16 de fevereiro	NDRE	0,23	1,56	2,01	Não significativo
16 de fevereiro	NDVI	0,33	2,28	2,01	Significativo

01 de março	NDRE	0,23	1,54	2,01	Não significativo
01 de março	NDVI	0,30	2,02	2,01	Significativo
11 de março	NDRE	0,15	0,97	2,01	Não significativo
11 de março	NDVI	0,24	1,59	2,01	Não significativo
13 de março	NDRE	0,15	0,96	2,01	Não significativo
13 de março	NDVI	0,19	1,27	2,01	Não significativo
18 de março	NDRE	0,14	0,92	2,01	Não significativo
18 de março	NDVI	0,23	1,51	2,01	Não significativo
23 de março	NDRE	0,14	0,93	2,01	Não significativo
23 de março	NDVI	0,27	1,85	2,01	Não significativo
28 de março	NDRE	0,09	0,56	2,01	Não significativo
28 de março	NDVI	0,28	1,91	2,01	Não significativo
31 de março	NDRE	0,03	0,16	2,01	Não significativo
31 de março	NDVI	0,17	1,14	2,01	Não significativo
02 de abril	NDRE	0,01	0,08	2,01	Não significativo
02 de abril	NDVI	0,19	1,27	2,01	Não significativo
10 de abril	NDRE	-0,01	-0,10	2,01	Não significativo
10 de abril	NDVI	0,02	0,10	2,01	Não significativo
12 de abril	NDRE	0,02	0,11	2,01	Não significativo
12 de abril	NDVI	0,00	-0,03	2,01	Não significativo
20 de abril	NDRE	0,01	0,05	2,01	Não significativo
20 de abril	NDVI	-0,22	-1,43	2,01	Não significativo

Ao analisar a Tabela 2 verificou-se que, os dados de correlação de NDVI tiveram variações de -0,22 até 0,48, com o maior resultado na data de 30.01.2023, onde a cultura da soja se encontrava entre os estádios R2 e R3. Schirmbeck, et al (2020) mencionam que, o NDVI possui curva espectral padrão onde as lavouras de ciclos anuais como a soja tendem a ter seus valores baixos de NDVI no início da cultura, quando ainda há a presença de solo exposto, e o crescimento vem em decorrência do acúmulo de biomassa verde, onde atinge o seu pico.

Por outro lado, o menor NDVI foi na data de 20.04.2023, o que pode ser explicado pelo fato de a cultura já estar no estado de maturação fisiológica completa, sabendo que foi realizada a colheita na data de 25.04.2024. De acordo com o estudo realizado por Farias et al. (2023), quanto mais próximo da data de colheita, menor será o valor de NDVI. Paralelamente a isso, Pontes et al. (2010) apontam que, o maior valor de NDVI é encontrado no pico do ciclo vegetativo da cultura.

Outrossim, o maior resultado de NDRE foi encontrado na data de 11.02.2023 apresentando 0,29 onde a cultura á estava em processo de avanço para o estádio R4, e o menor resultado foi na data de 10.04.2023 com NDRE -0,01. Assim, com base nos resultados obtidos, pode-se observar que, a melhor correlação do Índice NDVI apresenta valor significativo, o que poderia ser utilizado para analisar a produtividade da área. Portanto, os índices calculados para as datas observadas mostraram que, ao longo do estudo, houve pouca variação, sendo na maioria valores positivos, como apresentado na Figura 3.

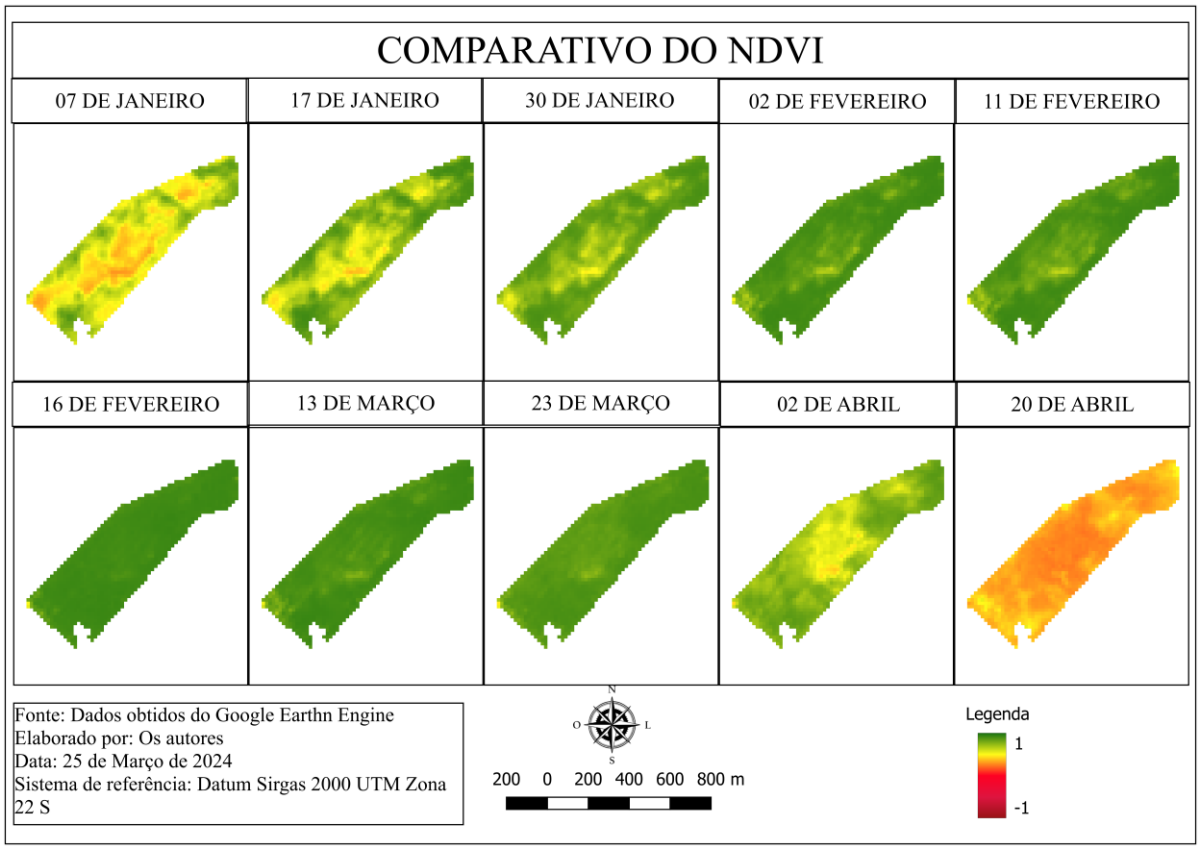


FIGURA 3: Comparativo temporal do NDVI.

Como pode ser observado na Figura 3, a data que apresentou melhor correlação (30.01.2023), visualmente apresentou características semelhantes às suas respectivas datas, 17 de janeiro e 02 de fevereiro confirmando que, apenas a comparação visual entre variáveis como índices e produtividade não podem ser correlacionadas. Também é possível afirmar que, datas próximas a colheita, a partir de 20.04.2023, já apresentavam tendência de não existência mais de correlação, demonstrando fundamental importância para a verificação e validação dos resultados obtidos. Ao analisarem o índice NDVI, Bertolo et al. (2005) afirmam que, valores maiores de NDVI representam atividade fotossintética ocorrendo de forma significativa, e o mesmo não ocorre ao contrário, quando a não presença de vegetação apresenta valores baixos. Portanto, essa afirmação se correlaciona com o caso resultante na cultura da soja no seu período de maturação, que não há mais a presença de vegetação e sim, de folha seca e solo exposto, fator que contribui para a presença de valores baixos no resultado encontrado. Ao observar a Figura 5, a data de 11.02.2023, que teve a melhor correlação do índice NDRE com a produtividade de grãos, apresentou características visuais semelhantes às datas de 02.02.2023 e de 16.02.2023 confirmando que, apenas a comparação visual entre variáveis como os índices e a produtividade de grãos, não podem ser correlacionadas. Também pode-se verificar que, a última análise realizada, na data de 10.04.2023, apresentou tendência de inexistência de correlação e índice NDRE mais baixo em relação às outras datas, confirmando fundamental importância o estudo de diferentes índices para a verificação e validação dos resultados obtidos neste trabalho.

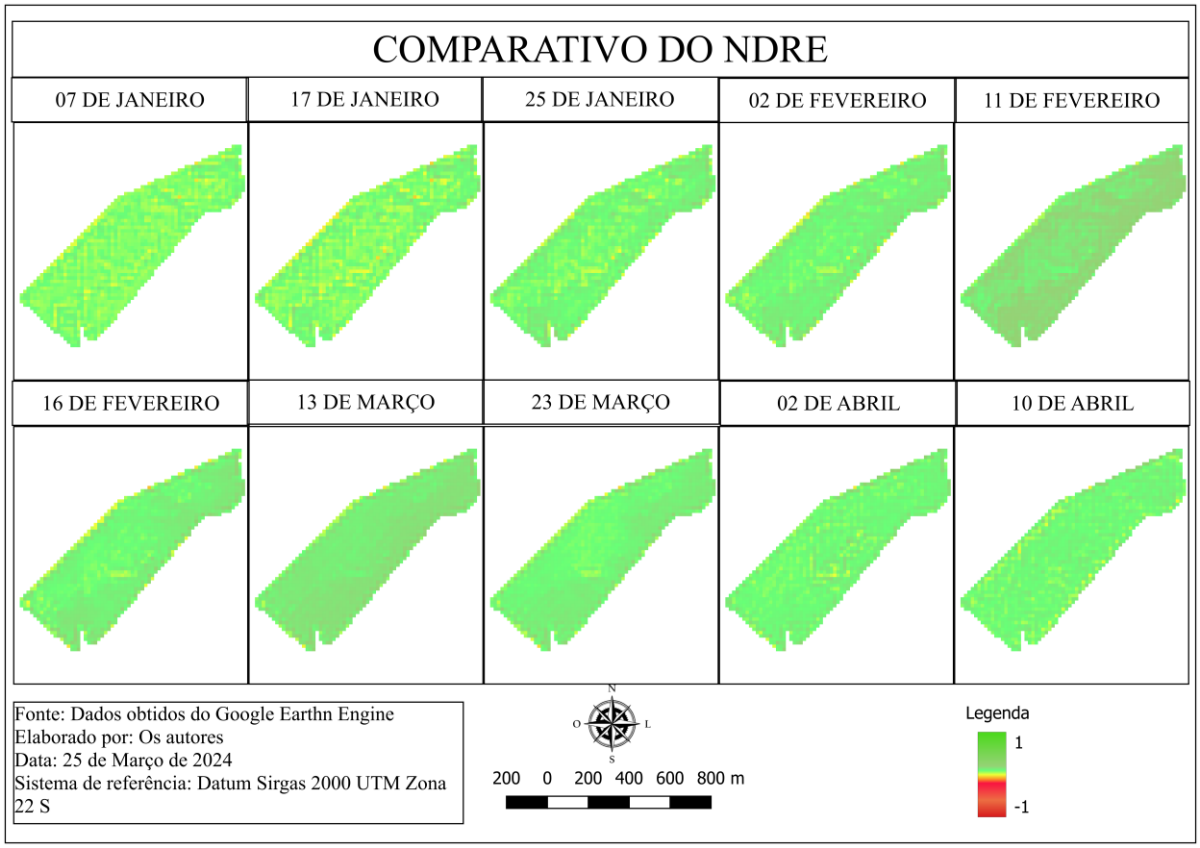


FIGURA 4: Comparativo temporal do NDRE.

Contudo, após a análise dos resultados, foi possível observar as possíveis causas de efeitos que pudessem interferir negativamente no resultado, descritos na metodologia do trabalho, como é o caso da resolução espectral do pixel 10 m, e as diferentes cultivares, não afetaram na análise dos dados. Em suma, a predição de safras por meio de sensoriamento, especificamente em sensores multiespectrais, cujas resoluções embora cada vez melhores e temporalidade de imageamento do mesmo local contribuem para a análise, é necessário considerar mais de uma safra e estudos sobre efeitos biofísicos e geofísicos de cada região em estudo.

CONCLUSÃO

Para este trabalho em específico, pode-se concluir que, as informações mostraram que é necessário considerar inúmeros fatores para a tomada de decisão de qual técnica de geoprocessamento deve ser utilizado para análise de dados geoestatísticos. A qualidade dos dados, assim como das imagens de satélite, que devem ter suas propriedades livres de distorções, corrigidas de interferências atmosféricas e reflectância de superfície. Além de tudo, acende o alerta para que estudos futuros associem outros fatores como condições climáticas, uso do solo, e comparativo entre dois ou mais ciclos de produção

AGRADECIMENTOS

Agradecimento especial ao Colégio Politécnico da UFSM

REFERÊNCIAS

BERTOLO, L, S; ROCHA, J. V; YOUNG, A. F. Evolução temporal do índice de vegetação na área urbana de Curitiba, PR. Goiânia. **Anais XII Simpósio Brasileiro de Sensoriamento Remoto.** 16 -

21 de abr 2005. p. 2051-2058, 2005. Disponível em: http://marte.dpi.inpe.br/col/ltid.inpe.br/sbsr/2004/11.20.00.11/doc/2051.pdf. Acesso em: 05 de abr. 2024.

FARIAS, G, D; BREEM. C; BREDEMEIER, C; MENEZES, J, L; ALVES, L, A; TIECHER, T; MARTINS, A, P; FIORAVANÇO, G, P; SILVA, G, P, da; CARVALHO, P, de, FACCIO. Normalized Difference Vegetation Index (NDVI) for soybean biomass and nutrient uptake estimation in response to production systems and fertilization strategies. 2023. Front. Sustain. Food Syst. 6:959681. Doi: 10,3389/fsufs.2022.959681.

FERREIRA, F, L, S; PEREIRA, E, B. Padrões construtivos e características espectrais associados aos outliers de temperatura de superfície. **Open Science Research VI**. Editora Científica Digital - Volume 6 - Ano 2022. Disponível em https://downloads.editoracientifica.com.br/articles/220910081.pdf. Acesso em 22 de mai.2024.

MOLIN, J. P; ANSELMI, A. A. Agricultura de precisão considera variabilidade das áreas de cultivo. **Visão Agrícola**, v. 13, n. jul./dez., 2015.

OLIVEIRA, R. G. DE, BACANI, V. M., SILVA, V. R. DA, CUNHA, E. R. DA, FERREIRA, E. M. Análise da fragilidade ambiental da bacia hidrográfica do córrego São João-MS utilizando geoprocessamento. **Revista Brasileira de Cartografia** 64 (1), 15-24, 2012.

PONTES, P. P. Breglio, et al. **Análise temporal de índices de vegetação como subsídio à previsão de safras de cana-de açúcar**. Anais XII Simpósio Brasileiro de Sensoriamento Remoto, Goiânia, Brasil, 16-21 abril 2005, INPE, p. 217-224.

PONZONI, F. J. Comportamento Espectral da Vegetação. In: MENESES, P.R.; MADEIRA NETO, J.S., (Eds). **Sensoriamento remoto**: reflectância de alvos naturais. Brasília: UNB/EMBRAPA, 2001. Disponível em: http://marte.dpi.inpe.br/col/ltid.inpe.br/sbsr/2004/11.21.21.12/doc/217.pdf. Acesso em 20 de mai.2024.

PONZONI, F. J; SHIMABUKURO, Y. E. **Sensoriamento Remoto no Estudo da Vegetação**. São José dos Campos/SP: Instituto Nacional de Pesquisas Espaciais - INPE, 2010.

ROQUE, A. Estatística 2 - Aula 15. 2014? Disponível em: http://sisne.org/Disciplinas/Grad/ProbEstat2/aula15.pdf. Acesso em 22 de mai.2024.

SCHIRMBECK, L. W, et al. Condições hídricas de lavoura de soja usando sensoriamento remoto terrestre. **Agrometeoros** Revista de sociedade brasileira de agrometeorologia. Passo Fundo, v.27, n.1, p.173-181, set 2019. Disponível em: https://ainfo.cnptia.embrapa.br/digital/bitstream/item/211776/1/Condicoes-hidricas-de-lavoura-de-soja-usando-sensoriamento.pdf. Acesso em 20 de mai.2024.

A IMPORTÂNCIA DA SUBAMOSTRAGEM NO MAPEAMENTO DOS ATRIBUTOS DO SOLO

Pedro Rodolfo Zolin [1]; Euriana Maria Guimarães [2]; Zigomar Menezes de Souza [3]; Maurício Roberto Cherubin [4]; Lucas Rios do Amaral [5]

[1]Graduando. Av. Cândido Rondon, 501 - Cidade Universitária, Campinas - SP, 13083-875. Faculdade de Engenharia Agrícola - Universidade Estadual de Campinas; [2]Doutoranda. Av. Cândido Rondon, 501 - Cidade Universitária, Campinas - SP, 13083-875. Faculdade de Engenharia Agrícola - Universidade Estadual de Campinas; [3]Professor titular. Av. Cândido Rondon, 501 - Cidade Universitária, Campinas - SP, 13083-875. Faculdade de Engenharia Agrícola - Universidade Estadual de Campinas; [4]Professor doutor. Av. Pádua Dias, 11 - Agronomia, Piracicaba - SP, 13418-900. Escola Superior de Agricultura Luiz de Queiroz - Universidade de São Paulo; [5]Professor associado. Av. Cândido Rondon, 501 - Cidade Universitária, Campinas - SP, 13083-875. Faculdade de Engenharia Agrícola - Universidade Estadual de Campinas

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

O mapeamento dos atributos químicos e físicos do solo em agricultura de precisão é geralmente realizado a partir de coleta de amostras em grade seguido por interpolação. Cada ponto dessa grade amostral é composto pela coleta de algumas subamostras, buscando diluir variações locais. Porém, a importância dessa coleta de subamostras, muitas vezes, é subvalorizada. Assim, neste trabalho demonstramos o grau de variabilidade que alguns atributos do solo apresentam entre as subamostras (resistência do solo à penetração - RP, fósforo - P e potássio - K disponíveis e teor de carbono total no solo). Para tanto, avaliamos a dispersão de valores de subamostras coletadas em nove pontos amostrais em uma área produtora de grãos. Verificamos grande dispersão dos valores das subamostras, com CV de 15,2 - 90,9% para RP, 15,2 - 75,3% para P, 15,6 - 76,2% para K e 6,9 - 14,7% para C. De forma geral, a sugestão é que não se deve coletar menos do que cinco subamostras para representar um único ponto.

PALAVRAS-CHAVE: Amostragem; qualidade de solo; mapeamento digital de solos

ABSTRACT

Mapping soil chemical and physical attributes in precision agriculture is generally carried out by collecting gridded samples followed by interpolation. Each point in this sampling grid comprises the collection of some subsamples, seeking to dilute local variations. However, the importance of this subsample collection is often undervalued. Thus, in this study, we demonstrate the degree of variability that some soil attributes present among the subsamples (resistance to penetration - RP, available phosphorus - P and potassium - K, and total carbon content in soil). To this end, we evaluated the dispersion of values from subsamples collected at nine sampling points in a grain-producing area. We found a large dispersion of subsample values, with CVs of 15.2 - 90.9% for RP, 15.2 - 75.3% for P, 15.6 - 76.2% for K, and 6.9 - 14, 7% for C. In general, the suggestion is that at least five subsamples must be collected to represent a single point.

KEYWORDS: ;

INTRODUÇÃO

Os atributos do solo variam ao longo das áreas agrícolas, seja por fatores intrínsecos à sua formação, seja por fatores extrínsecos, como as práticas de manejo e rotação de culturas (CAMBARDELLA e KARLEN, 1999). Para o mapeamento desses atributos e a consequente criação de mapas de

prescrição de fertilizantes em agricultura de precisão, o que predomina é a amostragem de solo em grade (COLAÇO e MOLIN, 2014).

Estabelecer um plano de amostragem do solo é uma das etapas mais importantes, já que é preciso conciliar o rendimento da operação, custos envolvidos e a qualidade do levantamento. Nesse sentido, quando se busca representar adequadamente um ponto amostral, é necessário definir um número de subamostras que será utilizado para representar uma amostra composta que tenha as coordenadas registradas. Em outras palavras, uma amostra é composta pela média dos valores das subamostras dentro de um raio relativo ao ponto amostral, o que possibilita reduzir possíveis efeitos locais que contaminariam a investigação espacializada (MOLIN et al, 2015). Entretanto, um número equivocado de subamostras pode prejudicar o resultado do mapeamento realizado.

Segundo MOLIN *et al* (2015), é recomendado que na amostragem em grade por ponto para fins de mapeamento da fertilidade dos solos, o número de subamostras deve ser entre oito e dez. Tal número seria suficiente para diluir possíveis riscos locais de contaminação da amostra, isto é, coleta em locais que não representam fielmente o local amostrado. No entanto, mesmo no caso da amostragem em grade para mapeamento dos parâmetros de fertilidade do solo, que são mais amplamente utilizados na agricultura de precisão, há carência de estudos quanto a essa demanda por subamostras. Por conta dessa falta de padronização, os usuários e prestadores de serviço em agricultura de precisão acabam balizando a decisão conforme resultados empíricos obtidos localmente, mas sem generalização ou rigor científico, ou, o que é ainda pior, conforme o tempo disponível para a realização da amostragem, não sendo raro encontrar levantamentos sendo realizados com a coleta de apenas três subamostras.

Além disso, nos últimos anos tem ganhado enfoque questões relacionadas à qualidade/saúde do solo (MENDES e CHERUBIN, 2024). Para tal levantamento, é necessária a caracterização de atributos químicos, físico e biológicos do solo (LEHMANN et al., 2020). Contudo, não há estudos que direcionem como a amostragem deve ser feita para a criação de mapas de saúde do solo, muito menos que abordem a demanda por subamostras.

OBJETIVOS

Assim, este trabalho buscou demonstrar a importância da coleta de subamostras para compor as amostras compostas e, assim, representar adequadamente os pontos amostrais. Assim, neste trabalho focamos em dois atributos de fertilidade química (P e K), um atributo físico (resistência do solo à penetração) e outro que é dependente de processos físicos e biológicos e muitas vezes têm sido usado para avaliar a saúde biológica do solo, e ainda cada vez mais importante devido a questões ambientais e financeiras, o teor de carbono total do solo.

MATERIAL E MÉTODOS

A área de estudo foi uma gleba produtora de grãos de 103 ha, localizada no município de Cosmópolis-SP. A classificação taxonômica dos solos foi realizada nessa área, assim como o levantamento da suscetibilidade magnética aparente do solo (SMa - sensor EM38-MK2, Geonics). Por meio de monitor de produtividade instalado na colhedora, seis safras de grãos foram mapeadas, resultando em um mapa de produtividade média e outro do desvio padrão, buscando demonstrar locais com maior variabilidade na produção entre as safras (FIGURA 1). Todos os dados foram projetados para o datum WG84 e sistema de coordenadas planas, UTM, zona 23 sul.
Como a área de estudo apresenta uma região com um Gleissolo e o restante com Latossolo, optamos por dividir a áreas em três macro-regiões, uma relativa ao Gleissolo e outras duas em função da variação textural dos Latossolos (FIGURA 1A). Em cada macro-região definimos três pontos de coleta de solos (FIGURA 2A), sendo que para a alocação desses pontos, foi utilizada a variabilidade

observada nas camadas de informação da SMa, da produtividade média e do desvio padrão da produtividade, buscando amostrar pontos que apresentassem alguma diferença nesses atributos.

Em cada ponto amostral, foram coletadas nove subamostras de solo indeformada, centralizadas em 10 cm de profundidade e espaçadas 2,5 m num raio de 5 m (FIGURA 2B). Além disso, para cada macro região, também foi definido um dos pontos amostrais para serem coletadas amostras centralizadas a 30 cm. Adicionalmente, imediatamente ao lado do local de coleta com anel volumétrico, coletou-se solo com um trado holandês, nas profundidades de 0-20 cm e de 20-40 cm para avaliação da fertilidade química e do teor de carbono total. Deste modo totalizamos 108 amostras deformadas e indeformadas, todas coletadas no período de novembro de 2023.

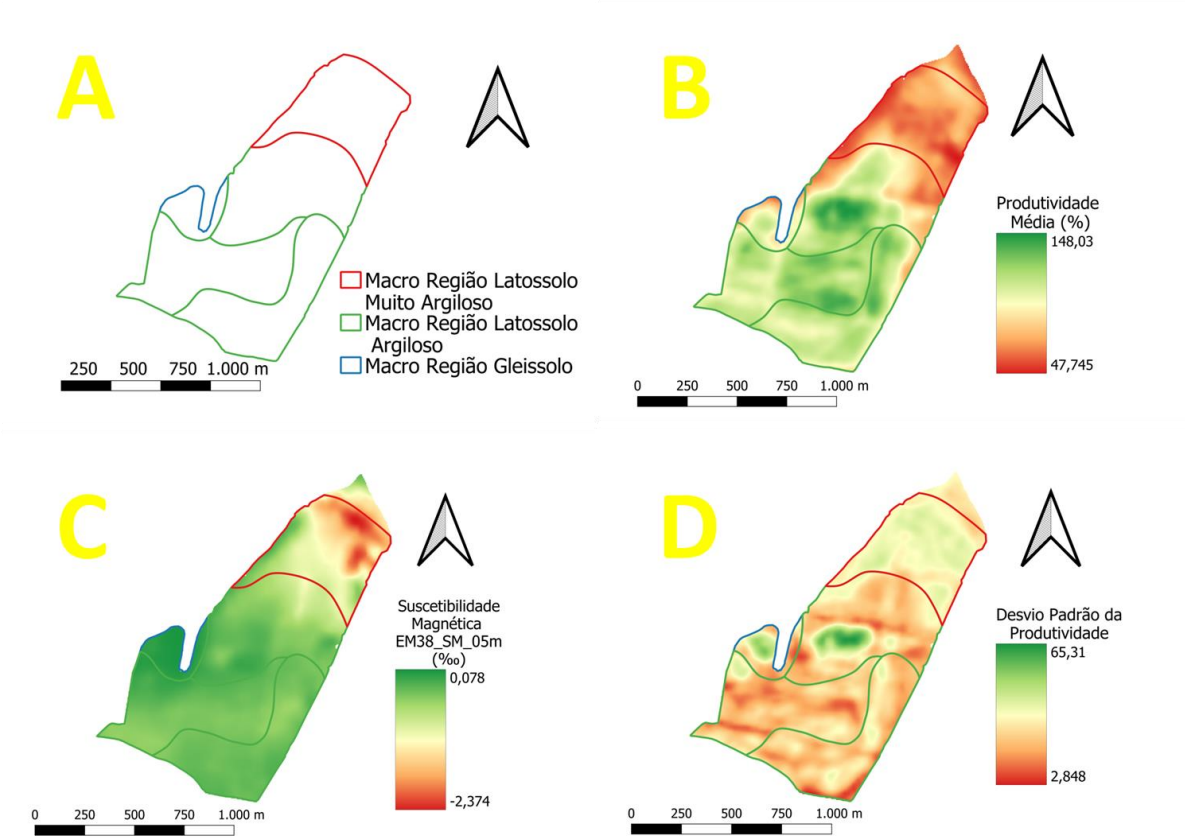


FIGURA 1 - Mapas da área de estudo com a delimitação das três macro-regiões compostas pelas classes de solo (A); Mapa de produtividade média normalizada (B), susceptibilidade magnética aparente do solo (C) e desvio padrão da produtividade normalizada das seis safras (D).

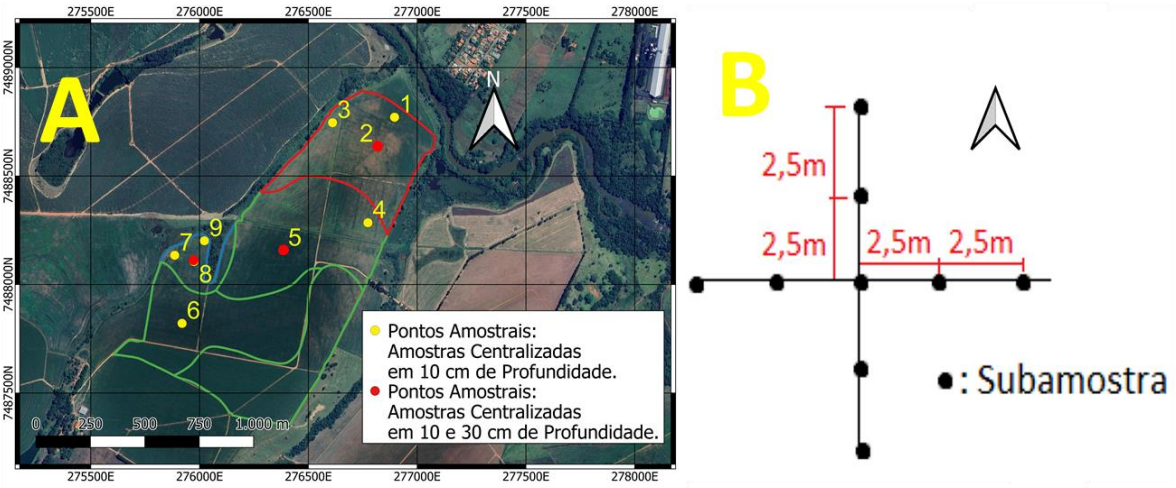


FIGURA 2 - Localização georreferenciada dos pontos amostrais na área (A) e esquema de coleta de subamostras para cada ponto amostral, onde cada subamostra foi espaçada em 2,5 metros (B).

As amostras indeformadas foram analisadas no laboratório de solos da FEAGRI para obtenção dos atributos físicos do solo: resistência do solo à penetração, densidade, macroporosidade, microporosidade e porosidade total (TEIXEIRA et al., 2017). As amostras deformadas foram encaminhadas para laboratório comercial para caracterização da fertilidade química do solo seguindo metodologia de RAIJ et al. (2001) e análise do teor de carbono total pelo método da combustão à seco (NELSON e SOMMER, 1996). Porém, neste trabalho optamos por explorar individualmente apenas quatro atributos, três que compõem a química do solo (P e K disponíveis e C total) e uma que entra na componente de física do solo (resistência do solo à penetração) quando calculando índices de saúde do solo (CHERUBIN et al., 2015).

RESULTADOS E DISCUSSÃO

Com relação aos teores de P e K, foi possível notar grande variação entre cada subamostra (FIGURA 3A e 3B). Interpretando os teores com base nos níveis "baixo", "médio", "alto" e "muito alto" presentes no Boletim 100 (CANTARELLA et al., 2022), é possível notar que as subamostras coletadas no mesmo ponto podem estar presentes em classes de disponibilidades distintas, o que geraria grande alteração nas doses de fertilizantes recomendadas. Essa variação é ainda mais acentuada para o P, provavelmente devido ao seu caráter "pouco-móvel" no solo (NOVAIS et al., 2007), o que o deixa ainda mais dependente do ponto de coleta da subamostra (MOLIN et al., 2015). Isso deixa claro a importância da coleta de subamostras para representar um único ponto de amostragem que será usado para interpolação e geração dos mapas de fertilidade em agricultura de precisão.

No caso da resistência do solo à penetração, isso também ocorre (FIGURA 3C). É possível observar que a dispersão dos valores das subamostras ainda é grande para a maioria dos pontos amostrais, contando também com alguns outliers, e mesmo que pareçam um pouco mais estáveis que os atributos químicos tratados, as subamostras de um mesmo ponto tendem a variar de três a quatro classes de valores entre "moderado", "alto", "muito alto" e "extremamente alto" (SOIL SURVEY STAFF, 2014). Portanto, para quantificação da resistência a penetração do solo, a coleta de subamostras para representação da amostra composta é tão importante quanto para a representação de atributos atrelados a fertilidade química dos solos.

Já para o carbono total do solo, como as classes de concentração não são claras, analisamos a variabilidade das subamostras com base no coeficiente de variação (CV) (FIGURA 3D), os quais são consideravelmente menores quando comparados aos dos demais atributos. Assim, além de visualmente o gráfico apresentar uma menor dispersão do valor das subamostras, o CV corrobora

isso. Isso mostra certa homogeneidade espacial e uma reduzida demanda por subamostragem para representar um ponto de coleta de amostra composta para determinação do carbono total do solo.

No caso da profundidade de amostragem, nota-se que para P, K e C, o solo mais profundo apresenta maior estabilidade nos valores, sendo menos dependente da coleta de alto número de subamostras. Isso é esperado, já que quanto mais profundo o solo, menor é a variação dos atributos do solo em função do manejo agrícola. A única ressalva é quanto à resistência do solo à penetração, já que a compactação dos solos pode ser mais evidenciada entre 20 e 30 cm (HAMZA e ANDERSON, 2005).

Em sequência, foi feito um teste calculando o valor médio para cada ponto amostral a partir de uma configuração de subamostragens pré-definidas, simulando possíveis configurações de coleta no campo (FIGURA 4). Nesse caso, fica relativamente evidente visualmente que o número mínimo de sete subamostras parece fazer com que o valor médio do ponto amostral seja estável para todos os atributos estudados na profundidade de 10 cm (FIGURA 5). Já no caso de 30 cm, esses atributos ficam mais estáveis, de modo que se observa que um número mínimo de cinco subamostras já seja suficiente. Também foi possível observar que para o C, esse número de subamostras pode ser ainda menor, pois em ambas as profundidades, a média foi estável a partir de três subamostras. Assim, pensando em caracterização química e física do solo, o número de subamostras não deveria ser inferior a cinco (no caso de limitações na amostragem), mas idealmente deveriam ser coletadas sete subamostras. Já para o levantamento de carbono total no solo, esse número pode ser menor, em torno de três subamostras já se mostra suficiente para diluir a maioria das variações observadas.

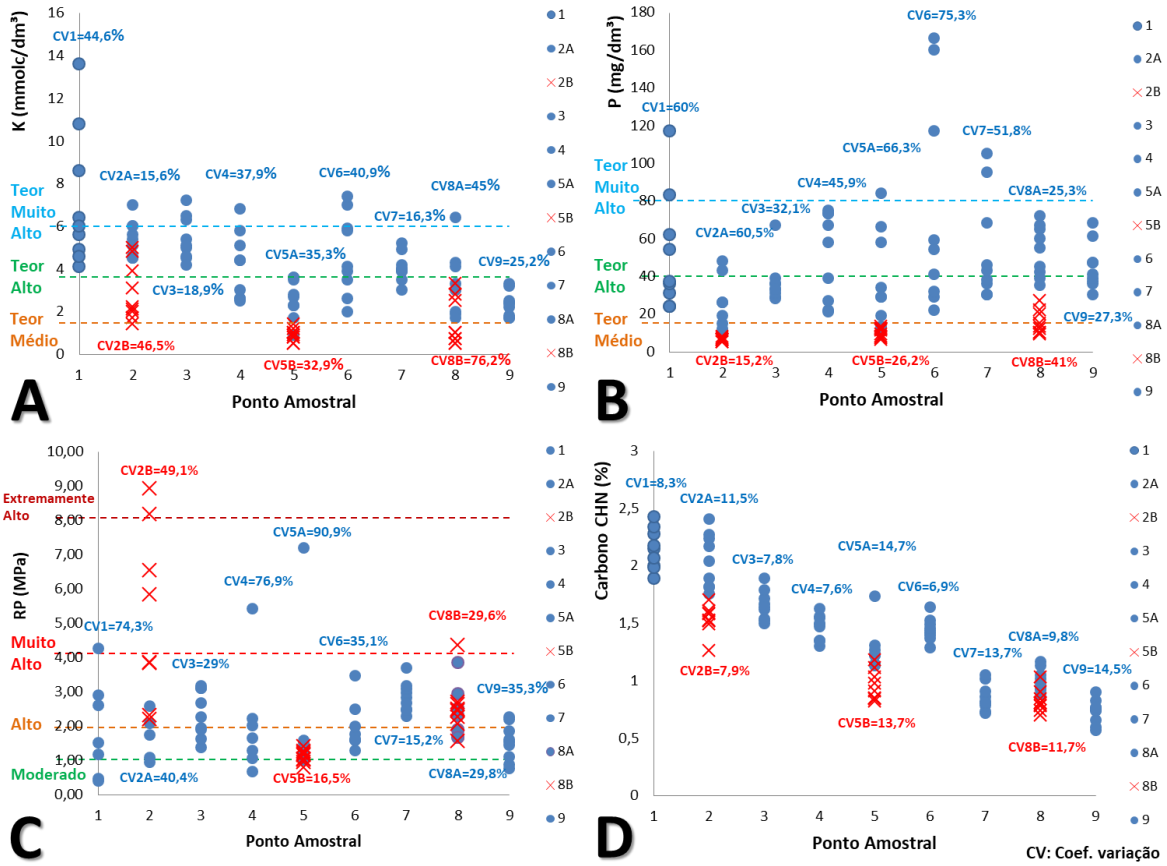


FIGURA 3 - Dispersão dos valores das subamostras (pontos em azul) para potássio (A), fósforo (B), resistência do solo à penetração (C) e teor de carbono total (D), indicando classes de teores e coeficiente de variação para cada amostra composta. Subamostras representadas com "X" vermelho se referem às coletadas em profundidade centrada em 30 cm.

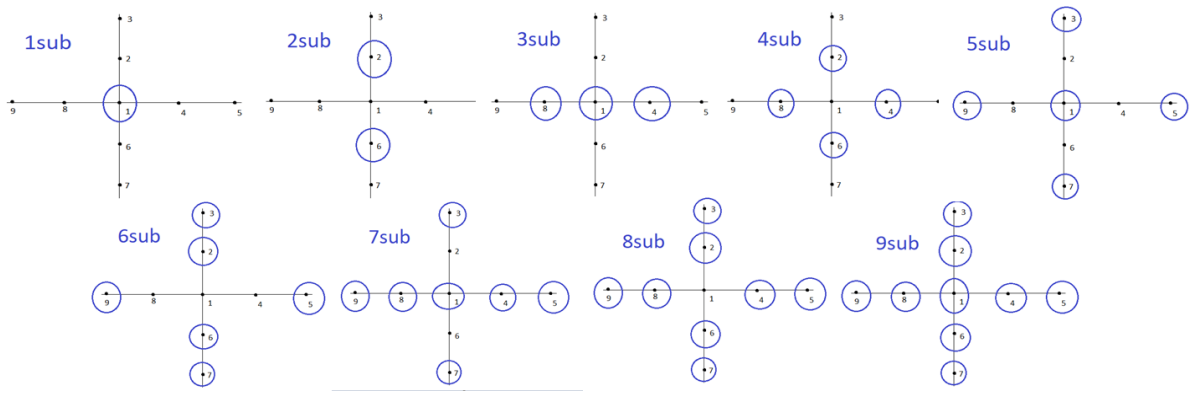


FIGURA 4 - Simulação do número de subamostras para representar um ponto amostral (valor médio); cenários com 1 a 9 subamostras, sendo que as subamostras com círculo representam as que foram usadas no cálculo da média.

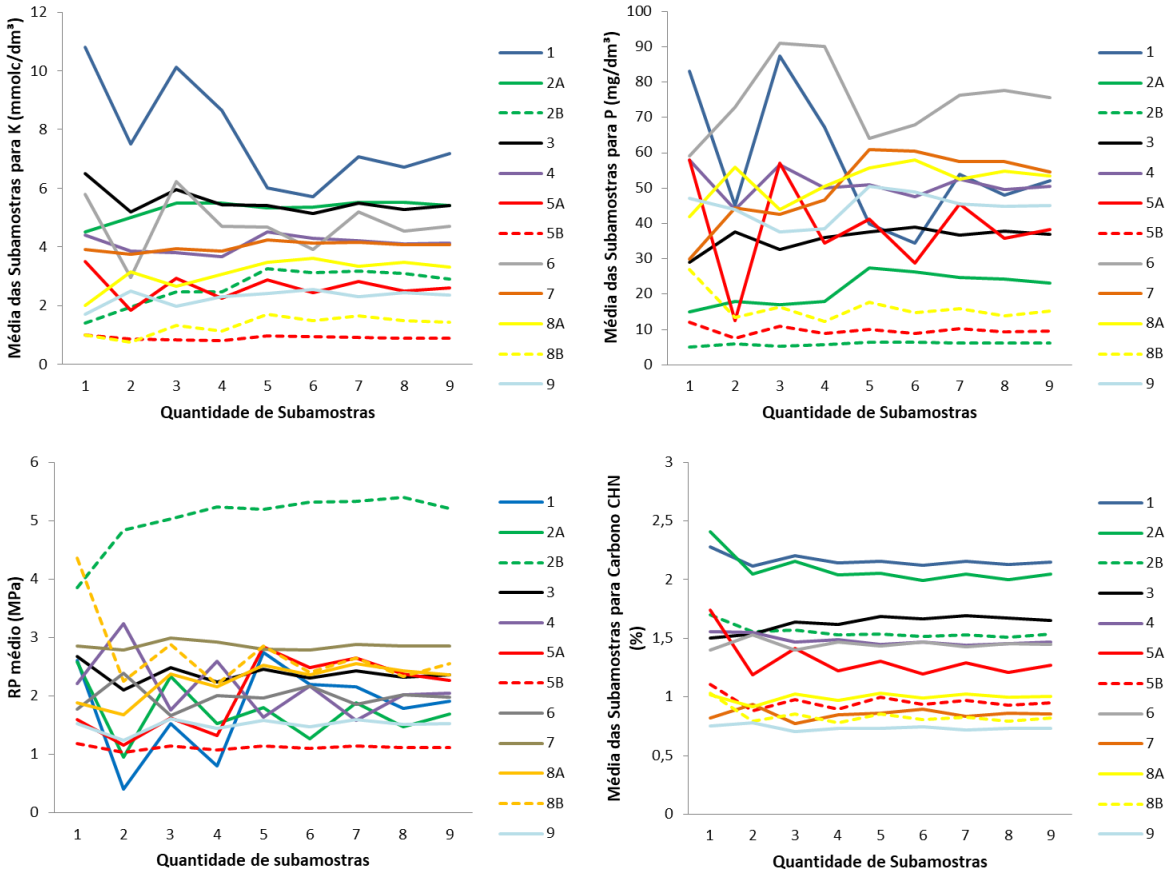


FIGURA 5: Valores médios de cada atributo do solo estudados, em função do número de subamostras utilizado no cálculo. Linhas tracejadas representam as coletas centradas em 30 cm de profundidade e linhas contínuas na profundidade de 10 cm.

CONCLUSÃO

Os atributos de fertilidade química (P e K) foram os que apresentaram maior dispersão nos valores de subamostras, seguido da resistência do solo à penetração, enquanto o carbono total no solo apresentou a menor variação. Desse modo, a coleta de subamostras para representar uma amostra composta (ponto amostral) é fundamental para a correta interpretação dos níveis de fertilidade e compactação, principalmente quando se almeja criar mapas no âmbito da agricultura de precisão.

Pensando em caracterização química e física do solo, o número de subamostras não deveria ser inferior a cinco (no caso de limitações na amostragem), mas idealmente deveriam ser coletadas sete subamostras para representar uma amostra composta. Para o levantamento do teor de carbono total do solo, esse número pode ser menor, em torno de três subamostras.

Quanto mais superficiais forem as coletas de solo para análise ou mensuração de dados a campo, maior é a importância das subamostras.

AGRADECIMENTOS

Agradecemos a todos os alunos dos laboratórios de Solos e de Agricultura de Precisão da FEAGRI/UNICAMP que contribuíram com a parte de campo ou de laboratório nessa pesquisa. Também agradecemos aos graduandos Pedro Chudzik e João Victor Müller Antigo do grupo SOHMA- ESALQ pela orientação técnica para a coleta de amostras indeformadas. Enaltecemos o apoio do CNPq com bolsa de iniciação científica ao primeiro autor e à FAPESP pelo apoio financeiro ao orientador, projeto n° 2022/03160-8.

REFERÊNCIAS

CAMBARDELLA, C. A.; KARLEN, D. L. Spatial analysis of soil fertility parameters. **Precision Agriculture**, v.1, p.5-14, 1999.

CANTARELLA, H. et al (ed.). **Boletim 100**: Recomendações de adubação e calagem para o estado de São Paulo. Campinas: Instituto Agronômico, 2022.

CHERUBIN, M. R. et al. Qualidade física, química e biológica de um Latossolo com diferentes manejos e fertilizantes. **Revista Brasileira de Ciência do solo**, v. 39, p. 615-625, 2015.

COLAÇO, A. F.; MOLIN, J. P. Amostragem georreferenciada, **Boletim Técnico 02**, Laboratório de Agricultura de Precisão, Departamento de Engenharia de Biossistemas, Escola Superior de Agricultura "Luiz de Queiroz", Universidade de São Paulo, 2014. Disponível em: <https://www.agriculturadeprecisao.org.br/boletim-tecnico-02-amostragem-georreferenciada/>.

HAMZA, M. A.; ANDERSON, W. K. Soil compaction in cropping systems: A review of the nature, causes and possible solutions. **Soil and Tillage Research**, v. 82, n. 2, p. 121-145, 2005.

LEHMANN, J. et al. The concept and future prospects of soil health. **Nature Reviews Earth & Environment**, v. 1, n. 10, p. 544-553, 2020

MENDES, I. C.; CHERUBIN, M. R. . Soil Health and Sustainable Agriculture in Brazil. 1. ed. Madison - Estados Unidos: ACSESS, 2024. v. 1. 432p

MOLIN, J. P.; AMARAL, L. R.; COLAÇO, A. **Agricultura de Precisão**. São Paulo, Oficina de Textos. 2015. 238 p.

NELSON, D.W; SOMMER, L.E. Total Carbon, Organic Carbon, and Organic Matter. In: Spark, D.L., Ed., Method of Soil Analysis, Part 3, American Society of Agronomy, v. 34, p. 961-1010. 1996

NOVAIS, R. F.; SMYTH, T. J.; NUNES, F. N. Fósforo. In: NOVAIS et al. (eds.). **Fertilidade do solo**. Viçosa-MG: Sociedade Brasileira de Ciência do Solo, 2007. p 471-550.

RAIJ, B. van et al. Análise Química para Avaliação da Fertilidade de Solos Tropicais. Campinas-SP: Instituto Agronômico, 2001. 285p.

SOIL SURVEY STAFF Keys to Soil Taxonomy 12 Ed. Washington: United States Department of Agriculture, Natural Resources Conservation Service. 2014. 372 ?.

TEIXEIRA, P. C. et al. **Manual de Métodos de Análise de Solos**. 3ª edição Revista e Ampliada, Brasília: Embrapa, 2017. 573p.

EFEITO DO ÂNGULO DA CAMERA EMBARCADA EM DRONE NA COLETA DE DADOS ESPECTRAIS E PREDIÇÃO DE BIOMASSA NA CULTURA DO MILHO

Bárbara da Silva Nogueira [1]; Ana Laura Pinto Mucillo [1]; Ana Julia Teixeira Soares [1]; Charleston dos Santos Lima [1]; Christian Bredemeier [2]

[1]Bolsista. Farroupilha, Porto Alegre - RS, 90010-150. Universidade Federal do Rio Grande do Sul; [2]Docente . Farroupilha, Porto Alegre - RS, 90010-150. Universidade Federal do Rio Grande do Sul

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Poucos estudos sobre a temática de diferentes ângulos de câmera no sensoriamento remoto existem atualmente, o que evidencia a necessidade de pesquisas sobre o assunto. Desta forma, o objetivo deste estudo foi avaliar a influência do ângulo da câmera nos valores dos indicies de vegetação e predição de biomassa na cultura do milho. Foram aplicadas 6 doses de N em cobertura, no estádio fenológico de 5 folhas (v5), em delineamento de blocos casualizados com 4 repetições. Após a aplicação dos tratamentos, nos estádios fenológicos v8, v13, R2 e R5, determinou-se a biomassa de plantas. Concomitantemente, realizou-se a coleta de imagens para a avaliação espectral das plantas nos ângulos de 90° e 55°. Evidenciou-se efeito significativo somente para o índice excesso de verde (EXG) e o índice de folha verde (GLI), com maior magnitude dos valores calculados com a posição do sensor a 55º. Além disso, a predição de biomassa com índices coletados a 55º resultou em métricas superiores comparado aos dados obtidos a 90º. Conclui-se que, a configuração do ângulo do sensor pode alterar os valores dos índices EXG e GLI, obtendo-se melhor acurácia na predição de biomassa na cultura do milho quando utilizou-se apenas o ângulo de 55° e a combinação de 90° e 55°.

PALAVRAS-CHAVE: Veículo aéreo não tripulado; Sensor; Índice de vegetação

ABSTRACT

Few studies currently exist on the subject of different camera angles in remote sensing, which highlights the need for research on the subject. Therefore, the objective of this study was to evaluate the influence of the camera angle on the vegetation index values ??and biomass prediction in maize. 6 doses of N were applied as top dressing, at the phenological stage of 5 leaves (v5), in a randomized block design with 4 replications. After applying the treatments, at phenological stages v8, v13, R2 and R5, plant biomass was determined. At the same time, images were collected for spectral evaluation of the plants at angles of 90° and 55°. A significant effect was only evident for the excess green index (EXG) and the green leaf index (GLI), with a greater magnitude of the values ??calculated with the sensor position at 55º. Furthermore, the biomass prediction with índices at 55º resulted in great metrics compared to data obtained at 90º. It is concluded that the configuration of the sensor angle can change the values ??of the EXG and GLI indices, obtaining better accuracy in predicting biomass in corn crops when only the 55° angle and the combination of 90° were used. and 55°.

KEYWORDS: Unmanned aerial Vehicle; sensor; vegetation index

INTRODUÇÃO

Nos últimos anos, o uso de veículos aéreos não tripulados (VANT's) tem aumentado significativamente para o monitoramento agrícola, com a presença de diferentes sensores (câmeras) acopladas a essas plataformas. Entretanto, o imageamento com o VANT é realizado exclusivamente com imagem de vista superior (90º), sem considerar que a maioria das folhas inferiores estão bloqueadas ou sombreadas, o que impede a análise abrangente de toda planta (RAHAMAN et al.,

2015). Logo, o uso de câmeras com diferentes ângulos pode ser uma estratégia para melhorar a caracterização de plantas a campo.

Recentemente, Zhang et al. (2019) avaliaram diferentes ângulos de imagem em plantas de milho sob condição controlada, os quais observaram que houve influência do ângulo da câmera em relação aos valores do índice de vegetação calculado e melhor caracterização de estresses abióticos em plantas. Tai autores observaram que o ajuste do sensor a 75° foi ideal para distinguir diferentes tratamentos de déficit hídrico, enquanto o ângulo de 15° foi adequado pra distinguir tratamentos de N, comparado a posição tradicional de 90º.

Poucos estudos sobre a temática de diferentes ângulos de câmera no sensoriamento remoto existem atualmente, o que evidencia a necessidade de pesquisas sobre o assunto.

OBJETIVOS

O propósito deste estudo foi avaliar a influência do ângulo da câmera no momento da aquisição de imagens por veículo aéreo não tripulado nos valores dos índices de vegetação e predição de biomassa na cultura do milho.

MATERIAL E MÉTODOS

O experimento foi conduzido junto à Estação Experimental Agronômica da Universidade Federal do Rio Grande do Sul (EEA-UFRGS), situada no município de Eldorado do Sul/RS (-30.11095 sul, -51.68116 oeste). A área experimental foi cultivada com aveia branca para cobertura do solo durante o inverno, sendo realizado a dessecação das plantas quando as mesmas estavam no estádio fenológico de florescimento.

A semeadura da cultura do milho foi realizada no dia 26 de outubro de 2023, sendo utilizado o híbrido P3016 VYHR, em sistema plantio direto com densidade de 8 plantas m², as quais já apresentavam tratamento de sementes industrial. A adubação de base foi constituída de 20 kg ha^{-1} N, 120 kg ha^{-1} P_2O_5 e 60 kg ha^{-1} K_2O. As unidades experimentais foram constituídas de 5 linhas de cultivo espaçadas a 0,5 metro e com 5 metros de comprimento, totalizando 12,5 m². Os demais tratos culturais foram feitos de acordo com as recomendações técnicas da cultura do milho.

Para garantir maior variabilidade na coleta de imagens, foram aplicadas seis doses de N em cobertura (0, 50, 100, 200, 300 e 400 kg ha^{-1}), na forma de ureia, com aplicação total realizada no estádio fenológico de cinco folhas completamente expandidas (Estádio V5), em delineamento de blocos casualizados com quatro repetições.

A coleta de imagens para avaliação espectral das parcelas foi realizada nos estádios V8 (oito folhas completamente expandidas), V11 (onze folhas completamente expandidas), V18 (dezoito folhas completamente expandidas), R2 (grão aquosos) e R5 (grão em massa dura). Todos os voos para a coleta de imagens foram realizados com auxílio de veículo aéreo não tripulado de asa rotativa DJI Phantom 4, com controle de voo autônomo via aplicativo Pix4D, o qual permitiu a obtenção da reflectância das plantas nos comprimentos de onda do vermelho (R: 660 nm), verde (G: 550 nm), azul (B: 450 nm), com resolução de 12 megapixels. As configurações gerais do voo consistiram de sobreposição frontal e lateral de 75% e altura de voo de 20 metros. Adicionalmente, foi alterado o ângulo da câmera dependendo do voo, sendo realizado um voo com a posição da câmera a 90º (nadir) e outro voo com a posição da câmera a 55º, ambos os voos realizados em sequência, sempre por volta do meio-dia em dias livres de nuvens. Imediatamente após os voos nos estádios fenológicos acima citados, foi realizada coleta de três plantas de milho em cada parcela do experimento, para determinação da biomassa seca da parte aérea, após secagem das plantas em estufa de aeração forçada a 65ºC por três dias, com os valores extrapolados para "quilograma de matéria seca por hectare".

O processamento de imagens foi realizado no software Agisoft Metashape para construção dos ortomosaicos com imagens obtidas na posição 90º e 55º para cada voo. Os quais foram associados a informações de sete pontos de controle de solo georreferenciados com GNSS-RTK para correção geométrica das fotos. Para a extração de informações espectrais dos ortomosaicos, utilizou-se o software Qgis e o plugin calculadora raster para o cálculo de diferentes índices de vegetação (Tabela 1).

Para verificar o efeito da posição da câmera na magnitude de valores, aplicou-se um teste-T ($p<0,05$) para comprovar a alteração espectral registrada pelo sensor de acordo com o ângulo utilizado. Posteriormente, os índices que apresentaram efeito significativo foram utilizados no modelo linear para a predição de biomassa, com a plotagem de modelos realizada conforme a posição da câmera no voo: 90º, 55º e combinação de ambos. Toda a análise estatística foi realizada no software Excel e R Studio (pacotes lm e ggplot2).

TABELA 1. Índices de vegetação calculados a partir dos voos realizados na cultura do milho.

Tipo	Índice	Equação
RGB	Excesso de verde	EXG= 2*(G(R+G+B)) - (R/(R+G+B)) - B/(R+G+B))
	Índice verde-vermelho normalizado	GRVI= (G – R) / (G + R)
	Índice resistente à atmosfera no visível	VARI= (G–R) / (G+R+B)
	Índice de folha verde	GLI= ((G-R) + (G-B)) / (2*G+R+B)

*R (red): vermelho; G (green): verde; B (blue): azul

RESULTADOS E DISCUSSÃO

Ao analisar os diferentes ângulos de imagem nos espectros de refletância da planta, evidenciou-se efeito significativo somente para o índice excesso de verde (EXG) e o índice de folha verde (GLI), com maior magnitude dos valores calculados com a posição do sensor a 55º (Figura 1). O que não foi observado para o índice verde-vermelho normalizado (GRVI) e o índice resistente a atmosfera no visível (VARI) (Figura 1). Tais resultados podem estar associados a parte da planta captada pelo sensor, uma vez que o ângulo oblíquo permite a coleta de imagens da posição mais interna do dossel, gerando valores maiores dos índices (LI et al., 2021). Adicionalmente, índices que utilizam a banda verde na sua formulação apresentaram maior correlação com o incremento de biomassa (BENDING et al., 2015). Logo, a resposta significativa para os índices EXG e GLI, pode estar associada a maior contribuição do verde no cálculo dos mesmos.

Buscando verificar o impacto dos diferentes ângulos na predição de biomassa na cultura do milho, constatou-se que os valores dos índices EXG e GLI a 55º resultaram em um coeficiente de determinação maior e um erro menor comparado aos dados obtidos a 90º (Figura 2). Além disso, ao agrupar os valores dos índices a 55º e a 90º, observou-se um coeficiente de determinação acima de 0,5, com erro médio absoluto 30% e 22% menor comparado a posição de 90º e 55º, respectivamente.

Embora o imageamento com VANT seja realizado exclusivamente com posição nadir, atualmente pesquisas tem evidenciado que a variação do sensor pode melhorar a estimativa de parâmetros biométricos. Recentemente, Stroner et al. (2021), concluiu que a combinação de dois voos com a mesma altitude, mas com diferentes câmeras (nadir e oblíqua) obtiveram resultados positivos na redução do erro sistemático de elevação, obtendo-se elevada acurácia na estimativa de altura de objetos quando se utilizou a fusão dos dados.

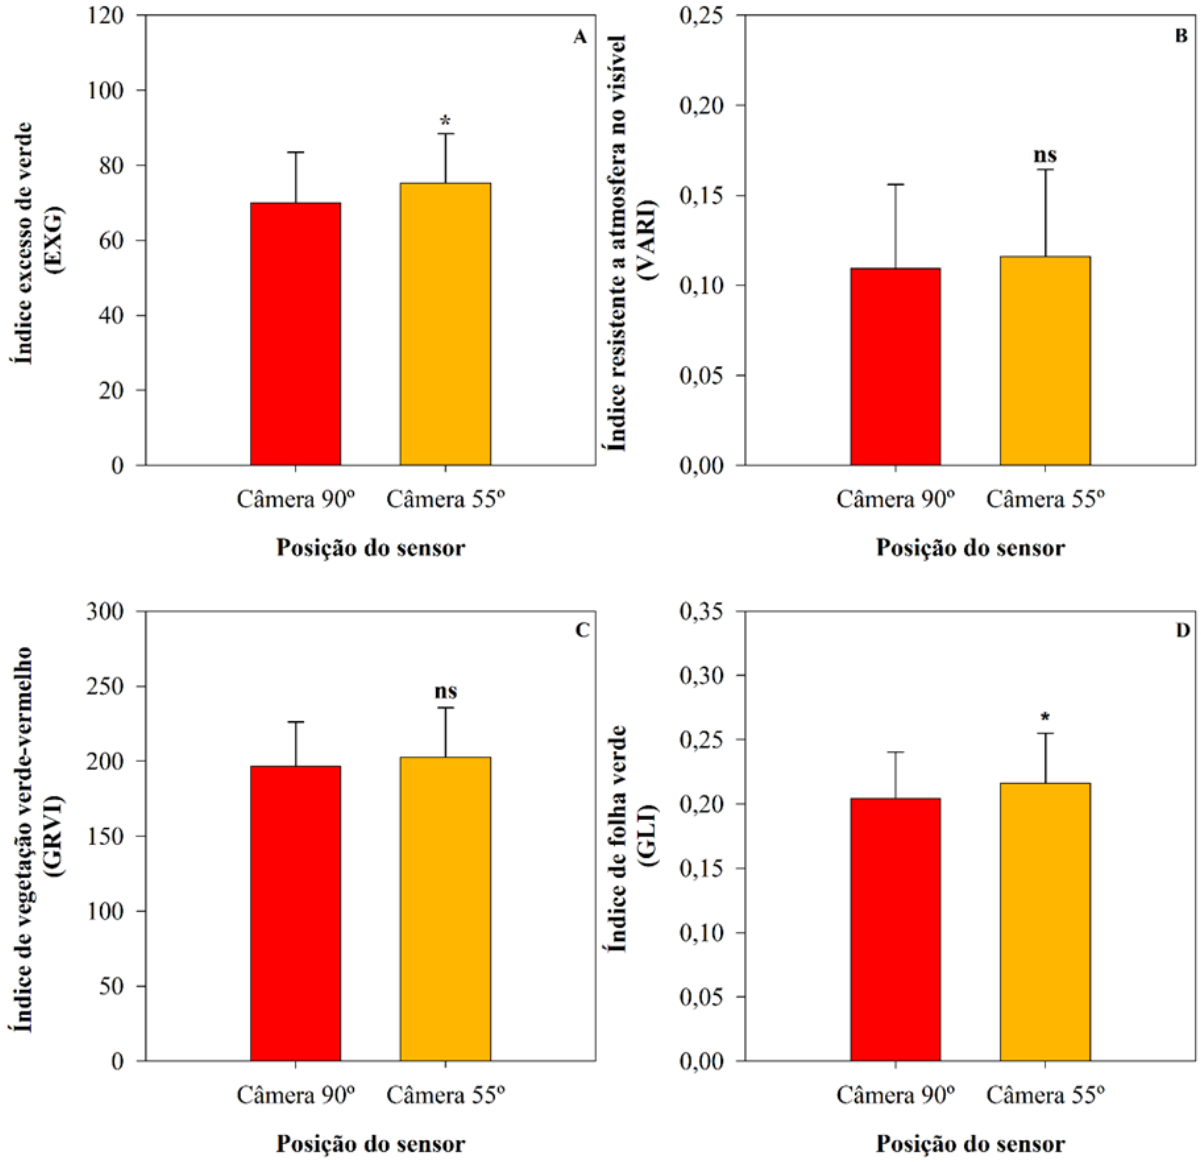


FIGURA 1 -Teste-t para comparar as duas condições de posição do sensor (90º e 55º) em quatro índices de vegetação calculados na cultura do milho, safra 23/24.

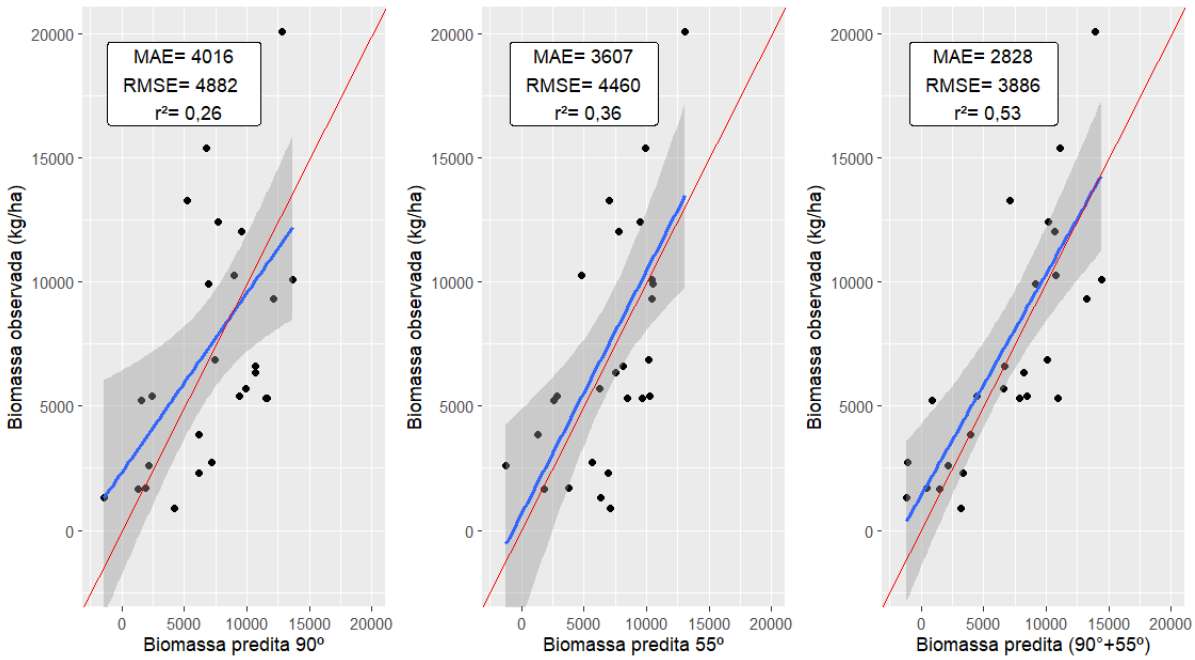


FIGURA 2 - Modelo linear de predição de biomassa utilizando os dados coletados a 90º, 55º e a combinação das duas posições do sensor.

CONCLUSÃO

Conclui-se que, a configuração do ângulo do sensor pode alterar os valores dos índices EXG e GLI, obtendo-se melhor acurácia na predição de biomassa na cultura do milho quando se utilizou apenas o ângulo de 55° e a combinação de 90° e 55°.

REFERÊNCIAS

BENDING, J.; YU, K.; AASEN, H.; BOLTEN, A.; BENNERTZ, S.; BROSCHEIT, J.; GNYP, M. L.; BARETH, G. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. **International Journal of Applied Earth Observation and Geoinformation**, v. 39, p. 79-87, 2015.

LI, M.; SHAMSHIRI, R. R.; SCHIRRMANN, M.; WELTZIEN, C. Impact of camera viewing angle for estimating leaf parameters of wheat plants from 3d point clouds. **Agriculture**, v. 563, p. 1-17, 2021.

RAHAMAN, M. M.; CHEN, D.; GILLANI, Z.; KLUKAS, C.; CHEN, M. Advanced phenotyping and phenotype data analysis for the study of plant growth and development. **Frontiers in Plant Science**, v. 6, p. 1-15, 2015.

STRONER, M.; URBAN, R.; SEIDL, J.; REINDL, T.; BROU?CEK, J. Photogrammetry using uav-mounted gnss rtk: georeferencing strategies without gcps. **Remote sensing**, v. 1336, p. 1-16, 2021.

ZHANG, L.; MAKI, H.; MA, D.; SÁNCHEZ-GALLEGO, J. A.; MICKERLBART, M. V.; WANG, L.; REHMAN, T. U.; JIN, J. Optimized angles of the swing hyperspectral imaging system for single corn

plant. **Computers and Electronics in Agriculture**, v. 156, p. 349-359, 2019.

AMOSTRAGEM MÍNIMA EM ZONAS DE MANEJO PARA CÁLCULO DA MÉDIA DOS ATRIBUTOS QUÍMICOS FÓSFORO E POTÁSSIO DO SOLO

LÍDIA DE OLIVEIRA BAHIA [1]; AMÉLIA LAISY DO NASCIMENTO [2]; EMANOEL DI TARSO DOS SANTOS SOUSA [2]; MARCO ANTONIO ZANELLA [2]; DANIEL MARÇAL DE QUEIROZ [3]

[1]Discente. Rua Dom Manuel de Medeiros, s/n - Dois Irmãos, Recife - PE, 52171-900. UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO; [2]Docente. Rua Dom Manuel de Medeiros, s/n - Dois Irmãos, Recife - PE, 52171-900. UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO; [3]Docente. Av. P H Rolfs, s/n - Campus Universitário, Viçosa - MG, 36570-900. UNIVERSIDADE FEDERAL DE VIÇOSA

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Na agricultura de precisão, zonas de manejo são comumente usadas com o objetivo de minimizar os custos de amostragem do solo, já que estas áreas são tratadas como homogêneas. No entanto, ainda pode haver variabilidade espacial dos atributos do solo nessas zonas, o que pode levar a erros na estimativa de suas propriedades quando uma amostragem insuficiente, ou má distribuída, é realizada. Dessa forma, verificou-se a quantidade mínima de amostras necessária para calcular a média dos atributos fósforo e potássio em cada classe das zonas de manejo. Tais zonas foram geradas com base em informações de índice de vegetação com diferença normalizada e condutividade elétrica aparente do solo nas profundidades de 0 a 20cm e de 0 a 40cm. A média e o coeficiente de variação dos atributos do solo foram calculados utilizando 2 amostras, incrementando 1 amostra até alcançar o máximo de amostras pertencentes a cada classe das zonas de manejo. O Índice de Performance Fuzzy (FPI) e a Entropia de Classificação Normalizada (NCE) indicaram que, para a variabilidade espacial dos dados, o número adequado de classes das zonas de manejo para a área de estudo foi 4. O número mínimo de amostras simples que representariam a maioria das classes (por meio da concordância com a referência) fica na faixa de 13 a 22 no caso do fósforo. Já no caso do potássio, a faixa é de 26 a 36 amostras simples. No entanto, houve casos que destoaram desse resultado majoritário, cujo número de amostras simples foi de ao menos 69 e 86 amostras.

PALAVRAS-CHAVE: variabilidade; manejo diferenciado; cafeicultura

ABSTRACT

In precision agriculture, management zones are commonly used with the aim of minimizing soil sampling costs, since these areas are treated as homogeneous. However, there can still be spatial variability of soil attributes in these zones, which can lead to errors in the estimation of their properties when insufficient or poorly distributed sampling is carried out. The minimum number of samples needed to calculate the average of the phosphorus and potassium attributes in each class of management zones was therefore verified. These zones were generated based on information from the normalized difference vegetation index and the apparent electrical conductivity of the soil at depths of 0 to 20cm and 0 to 40cm. The mean and coefficient of variation of the soil attributes were calculated using 2 samples, increasing by 1 sample until the maximum number of samples belonging to each class of management zones was reached. The Fuzzy Performance Index (FPI) and the Normalized Classification Entropy (NCE) indicated that, for the spatial variability of the data, the appropriate number of management zone classes for the study area was 4. The minimum number of single samples that would represent the majority of the classes (through agreement with the reference) is in the range of 13 to 22 in the case of phosphorus. In the case of potassium, the range is 26 to 36 single samples. However, there were cases that deviated from this majority result, where the number of simple samples was at least 69 and 86.

KEYWORDS: variability; distinct management; coffee farming

INTRODUÇÃO

Para enfrentar o desafio de produzir alimentos de forma sustentável e atender às demandas crescentes da população, a agricultura do futuro necessita aumentar a produtividade, extraindo o máximo de valor de cada etapa do ciclo de produção (BASSOI et al., 2019). Nesse cenário, a agricultura de precisão (AP) é uma ferramenta importante para o manejo de culturas de forma mais eficiente quanto ao uso de recursos, produtividade, qualidade, lucratividade e sustentabilidade da produção agrícola (MOLIN et al, 2020).

A AP compreende um ciclo que se inicia na coleta, análise e interpretação de dados, seguidos de geração de recomendações, aplicação em campo e avaliação dos resultados (GEBBERS; ADAMCHUCK, 2010). O principal produto para as decisões gerenciais sobre o manejo da cultura são mapas de produtividade, altimetria, parâmetros do solo ou da planta, dentre outros. Os mapas são produzidos a partir da coleta de dados que representem a possível variabilidade do atributo estudado. Para que os mapas sejam confiáveis, e consequentemente tenham acurácia mais elevada, é necessária grande coleta de amostras, resultando assim no aumento de custos para aplicação da agricultura de precisão (ANCHIETA, 2012).

A delimitação de zonas de manejo tem se mostrado uma boa alternativa na prática de agricultura de precisão, através do tratamento de dados por métodos estatísticos e computacionais eficientes, sendo base da maioria das práticas de AP (GEORGI et al., 2018; ROSA, 2021). Fazendo as delimitações das zonas de manejo, o custo para amostragem é reduzido consideravelmente, trazendo um melhor custo-benefício para aplicação da agricultura de precisão. Em teoria, as zonas de manejo são áreas com homogeneidade nas características que limitam a produtividade. Em relação à área como um todo, as zonas de manejo realmente terão menor variabilidade. No entanto, na prática, dentro de uma mesma zona de manejo, é possível que ainda exista alguma variabilidade espacial dos atributos. Dessa forma, uma amostragem composta por amostras simples insuficientes pode levar a erros na estimativa dos atributos.

OBJETIVOS

Analisar a quantidade mínima de amostras simples necessária para constituir uma amostra composta que por sua vez deve ser usada para definir o valor médio dos atributos do solo nas zonas de manejo

MATERIAL E MÉTODOS

Para o presente trabalho foi utilizado um banco de dados com informações de uma lavoura de café - espécie Coffea arábica L. - localizada na Fazenda Braúna (20°42'33" S, 42°34'17" W), município de Araponga, Minas Gerais, Brasil. A lavoura com área total de 20,2 ha, passou pelo processo de recepa (poda próximo ao nível do solo e mais drástica aplicada em planta depauperadas ou deformadas) em dezembro de 2014.

O banco de dados contém informações de vários atributos obtidos de 275 amostras de solo, mas neste trabalho foram usadas apenas os dados de fósforo (P), potássio (K), condutividade elétrica aparente do solo (CEa) nas camadas de 0 a 0,20 m (CEa20) e de 0 a 0,40 m (CEa40). Estas informações precisaram ser interpoladas para a área total, pois, a amostragem foi realizada seguindo uma malha sistematizada com base nas linhas de cultivo do café e espaçamento entre amostras de aproximadamente 25m. Os dados foram coletados em fevereiro de 2015.

Os pontos de amostragem no campo foram georreferenciados com o GPS Topográfico (L1), da marca Trimble, modelo Pro XT. Cada amostra foi composta por duas subamostras simples na profundidade de 0 a 0,20 m, coletadas em um raio de 1m ao redor do ponto georreferenciado. A CEa20 e a CEa40

foram obtidas com a utilização de um medidor portátil fabricado pela Landviser®, modelo LandMapper® ERM-02.

As zonas de manejo foram delimitadas a partir de 3 informações: CEa20; CEa40; e, índice de vegetação com diferença normalizada (NDVI - do inglês Normalized Difference Vegetation Index) da lavoura de café. O NDVI foi obtido a partir de imagens capturadas pelo sensor LISS-III do satélite Resourcesat-2 na data de 17 de outubro de 2014 cuja resolução é de 20 m. As imagens dessa data foram escolhidas por não apresentarem nuvens sobre a área de estudo dentre as imagens de datas anteriores à recepa da cultura ocorrida em dezembro de 2014.

As imagens adquiridas foram processadas no programa computacional QGIS versão 3.16.10 (QGIS DEVELOPMENT TEAM, 2021). Primeiro, foi feito o georreferenciamento das imagens e posteriormente, foram realizados: a calibração radiométrica; a correção atmosférica das imagens pelo método Object Subtraction (DOS); e a correção topográfica por meio do método empírico-rotacional (TAN et al., 2010; TAN et al., 2013). Após o tratamento das imagens, no mesmo ambiente SIG, foi realizado o cálculo do NDVI.

O plugin smart-map foi utilizado para a análise de semivariância e detecção de dependência espacial. Vários modelos de variogramas foram ajustados aos dados e, para cada variável estudada, foi escolhido o que apresentou maior coeficiente de determinação (R^2) e menor valor de Raiz do Erro Quadrático Médio (RMSE) dos modelos de variogramas ajustado.

Os dados foram interpolados por meio de krigagem ordinária com base nos variogramas determinados anteriormente. A interpolação foi realizada utilizando o plugin smart-map. O NDVI precisou ser interpolado para que os mapas de CEa20, CEa40 e NDVI ficassem com a mesma resolução de 5 m. Na sequência do trabalho, foram gerados os mapas do NDVI, da CEa20 e da CEa40. Para interpolação dos dados NDVI foi necessário retirar alguns pontos marginais e sobre a estrada para evitar o uso de pixels do NDVI que não correspondiam à cultura do café. Foi necessário também multiplicar os resultados do NDVI por 10 para uma melhor representação do mapa de variabilidade espacial, pois o smart-map possui uma limitação no número de casas decimais consideradas na análise de semivariância. A metodologia de Barnett e Lewis (1994) foi utilizada na verificação e identificação de valores discrepantes, também chamados de outliers. Todos as variaveis utilizadas no presente trabalho foram analisadas e os dados discrepantes excluídos para interpolação e geração dos mapas.

Com os mapas de variabilidade espacial de NDVI, CEa20 e CEa40 foram geradas classes de zonas de manejo, e o número de classes foi determinado com os menores valores de FPI e NCE simultaneamente. Após a escolha do número de classes, foi elaborado o mapa com as zonas de manejo, sendo estas geradas com os seguintes parâmteros do smart-map: n° máximo de iterações = 100 e Coef. Fuzzy = 1,25. O tamanho dos pixels dos mapas das classes e zonas de manejo foi de 5 × 5 m.

Com as classes e zonas de manejo criadas, foi calculada a estatística descritiva para os atributos químicos fósforo (P) e potássio (K), a fim de determinar uma quantidade mínima de amostras para representação da classe e análise do solo. Para esta etapa de processamento dos dados, foi utilizado o programa computacional R versão 4.1.2 (R TEAM, 2021). Inicialmente, foram determinados para cada atributo (P e K) os pontos pertencentes a cada zona de manejo, separando-os em classe 1, classe 2, classe 3 e classe 4. Com os pontos separados por classe, para cada atributo foi calculada a estatística descritiva: média, desvio padrão e coeficiente de variação (CV). Os cálculos iniciais consideraram duas amostras. Em seguida, a média, o desvio padrão e o CV foram calculados com 3 amostras. E assim, sucessivamente até que o cálculo da média, desvio padrão e CV fosse feito com todas as amostras pertencentes a cada classe. Esse procedimento iterativo foi repetido 1000 vezes para simular amostragens distintas e minimizar o efeito da aleatoriedade na análise. Dessa forma, as informações estatísticas calculadas em cada iteração foram frutos de pontos amostrais distintos cuja escolha

ocorria de maneira aleatória. O procedimento foi repetido para todas as classes e para os atributos P e K.

Para comparação da classificação do CV, foi gerado um gráfico a partir das iterações e realizado a classificação conforme Nogueira (2007) (Tabela 1). Com isso, foi possível analisar o comportamento do CV, para os atributos P e K, de cada classe de manejo em função do número de amostras coletadas em campo.

TABELA 1: Classificação do Coeficiente de Variação. Fonte: adaptado de Nogueira (2007)

CV < 35 %	Série homogênea; média significativa
35 % < CV < 65 %	Série heterogênea; média com pouco significado
CV > 65 %	Série muito heterogênea; média sem significado

O CV calculado a partir de todos os pontos amostrais contidos em determinada classe foi considerado como referência. Após realização das 1000 simulações foi calculada a probabilidade de cada resultado ocorrer. Foi considerado que o número de amostras não é suficiente para representar a classe de manejo, quando, em mais de 5% das 1000 simulações, o CV calculado com essas amostras recebeu uma classificação distinta à classificação do CV de referência (5% de significância). O número mínimo de amostras a serem consideradas para obtenção da estatística descritiva de cada classe de manejo foi definida, então, como o número de pontos em que o CV calculado recebeu a mesma classificação do CV de referência em, ao menos, 95% das 1000 simulações (acima de 95% de probabilidade).

RESULTADOS E DISCUSSÃO

Dos modelos de semivariograma teóricos existentes, os que explicam a maioria dos fenômenos espaciais são: esférico, exponencial e gaussiano (YAMAMOTO, 2015). Dentre esses modelos, para as variáveis NDVI, CEa20 e CEa40, o modelo que melhor se adequou aos valores analisados foi o esférico, pois foi o que apresentou menor RMSE e maior R2 na validação cruzada. Além de um baixo valor de RMSE, o menor valor do efeito pepita foi levado em consideração para escolha dos modelos teóricos, pois segundo Sartori (2014) muitas propriedades do solo apresentam esta descontinuidade na origem do modelo, sendo o efeito pepita uma variação espacial inexplicável ou puramente aleatória. Quanto maior o efeito pepita, maior sua aleatoriedade, e então, por consequência, a amostragem se torna insuficiente para o nível de variabilidade espacial estudada (YAMAMOTO, 2015). A Tabela 2 apresenta os valores dos parâmetros do modelo teórico escolhido para posterior determinação das zonas de manejo enquanto que a Figura 2 mostra os ajustes destes semivariogramas.

TABELA 2: Parâmetros dos modelos teóricos de variograma ajustados às variáveis para determinação das zonas de manejo.

Variável	Modelo	Efeito Pep.	Contribuição	Alcance	RMSE	R^2
NDVIx10	Esférico	0,00023	0,00061	212,814	0	0,987
CEa20	Esférico	0,384	0,526	74,557	0,002	0,695
CEa40	Esférico	0,325	0,399	127,126	0,002	0,662

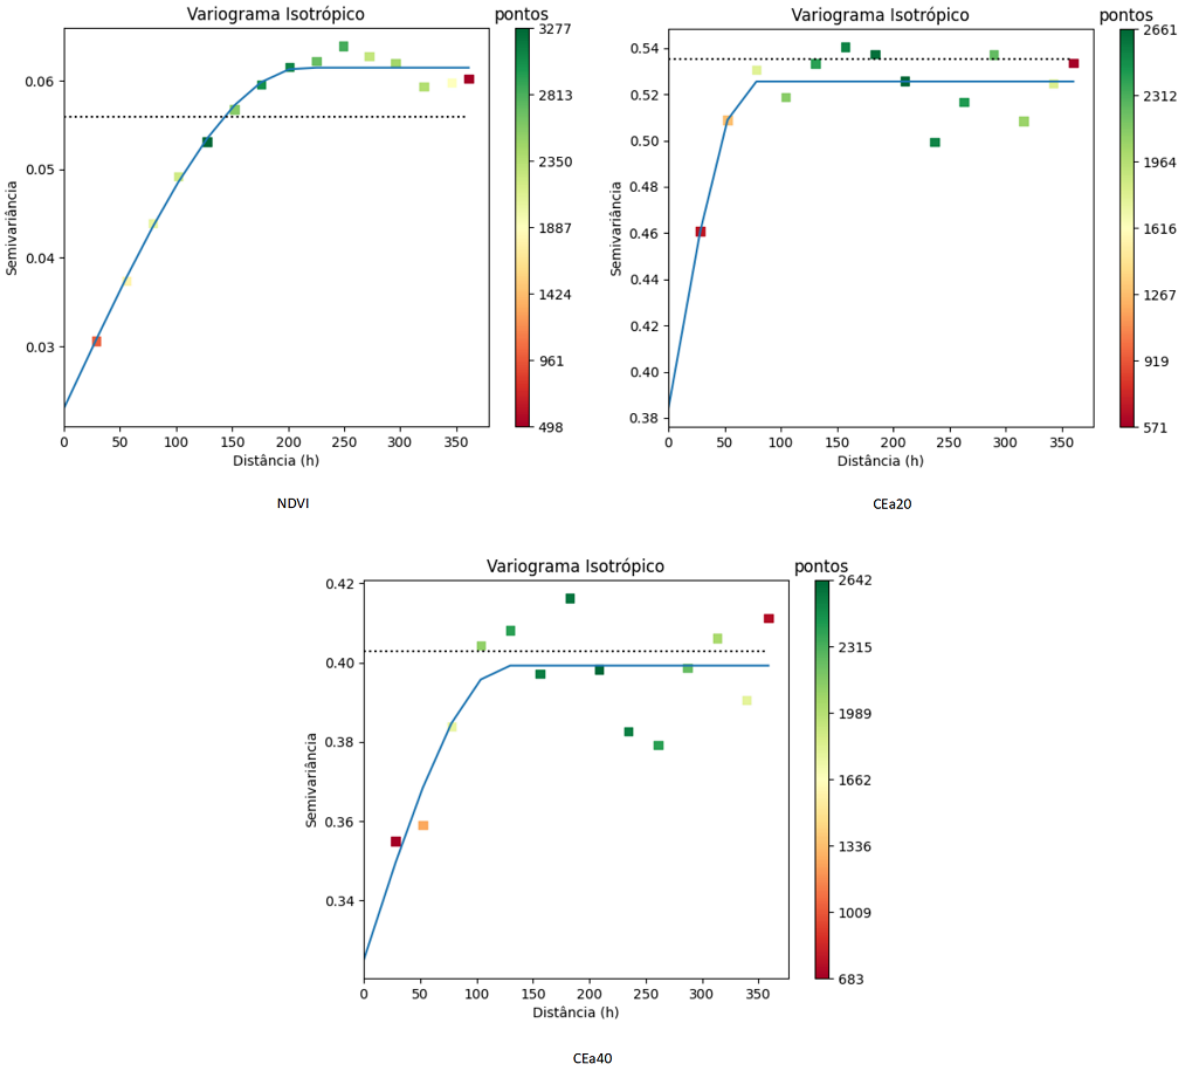


FIGURA 2: Variogramas (modelo esférico) ajustados às variáveis para determinação das zonas de manejo.

A partir dos variogramas ajustados foram gerados mapas interpolados de krigagem para cada uma das variáveis estudadas. A condutividade elétrica, tanto para profundidade 20cm quanto a 40cm, apresentou valores baixos ao centro da propriedade.

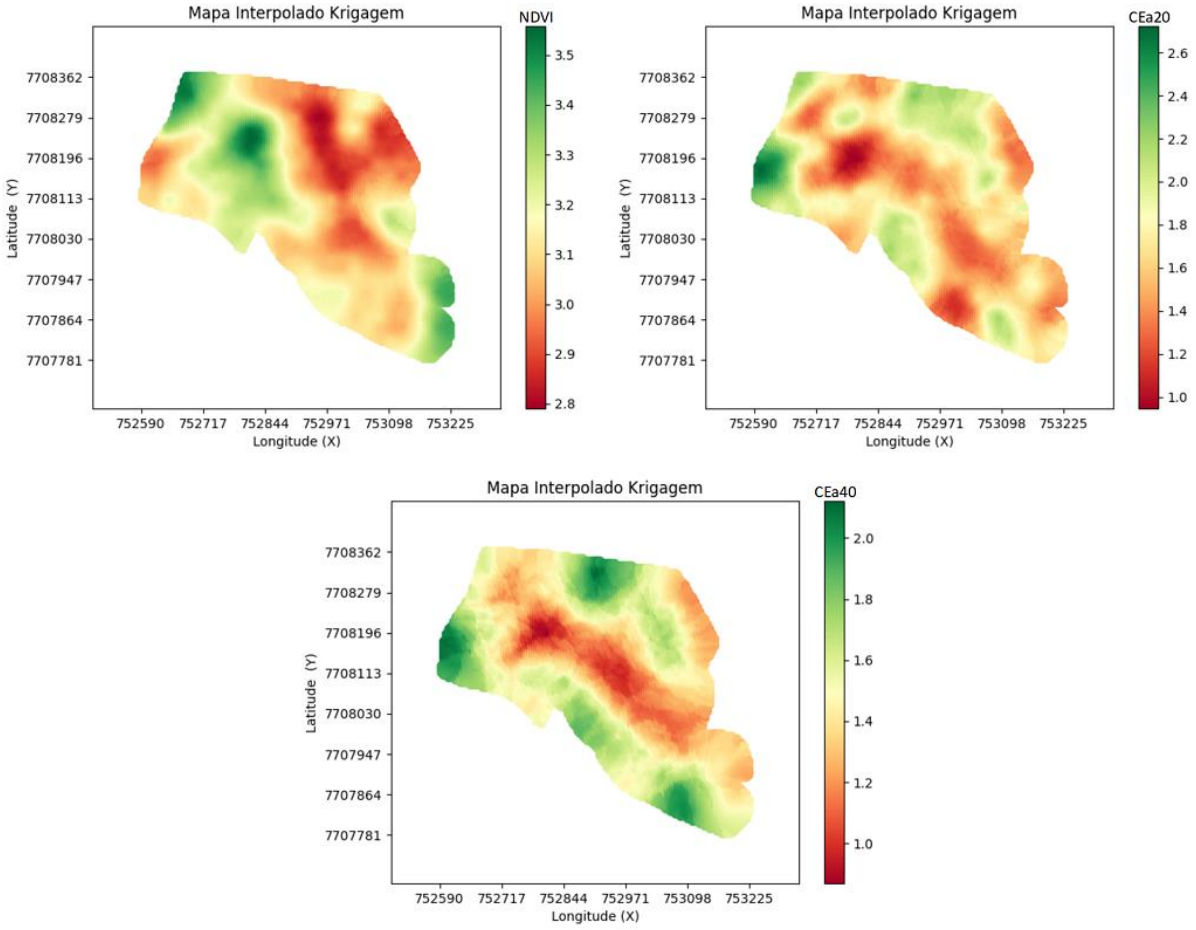


FIGURA 3: Mapas dos dados interpolados das variáveis NDVI, condutividade elétrica na camada 20cm (CEa20) e condutividade elétrica na camada 40cm (CEa40).

Do cruzamento dos dados dos mapas interpolados por krigagem para NDVI, CEa20 e CEa40, foram gerados os gráficos de Índice de Performance Fuzzy (FPI) e Entropia de Classificação Normalizada (NCE) (Figura 4a). A partir deles, o número adequado de classes das zonas de manejo escolhido para a área de estudo foi 4, onde os índices são mínimos ao mesmo tempo. O mapa das zonas de manejo da área de estudo é representado pela Figura 4b.

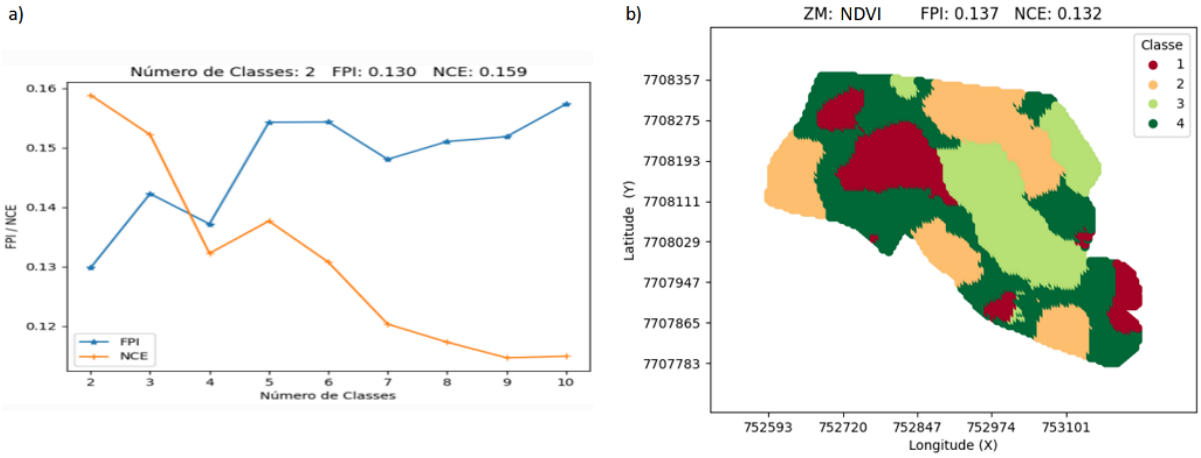


FIGURA 4: (a) Gráficos FPI e NCE. (b) Mapa das zonas de manejo.

A Figura 5 mostra a relação do coeficiente de variação (CV) do atributo químico fósforo (P) para cada uma das zonas de manejo em relação a quantidade de pontos amostrados. Com exceção da classe

2, há uma convergência dos valores de CV para classificação "heterogêneo". Na classe 2, os valores de CV convergiram para duas classificações, "heterogêneo" e "muito heterogêneo".

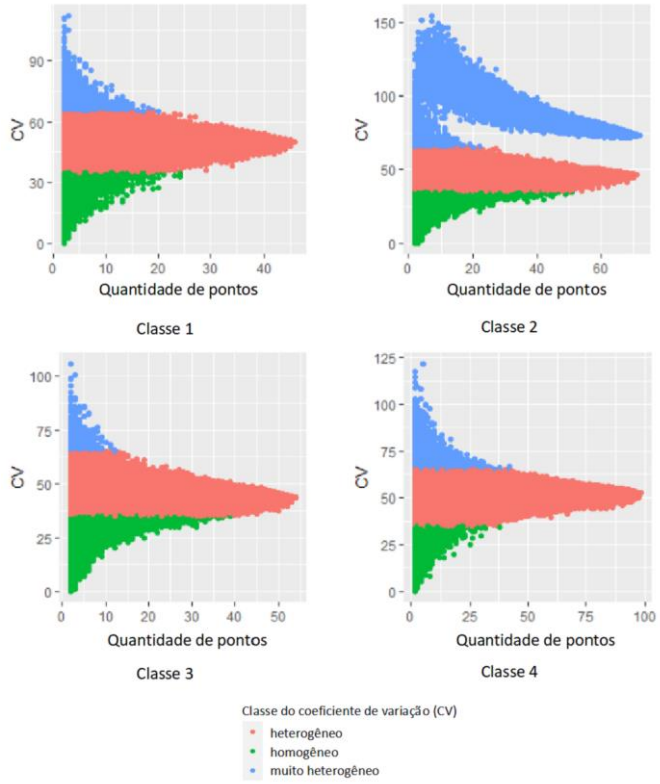


FIGURA 5: Gráficos de comparação de Coeficiente de Variação (CV) de fósforo (P) nas classes 1, 2, 3 e 4 em relação a quantidade de pontos coletados em campo.

A Figura 6 mostra a relação do coeficiente de variação (CV) do atributo químico Potássio (K) para cada uma das zonas de manejo em relação a quantidade de pontos amostrados. Os valores de CV do K convergiram para uma única classificação em todas as classes. Para as classes 1 e 3 os valores de CV convergiram para classificação "heterogêneo". Já para as classes 2 e 4, os valores de CV convergiram para a classificação "homogêneo".

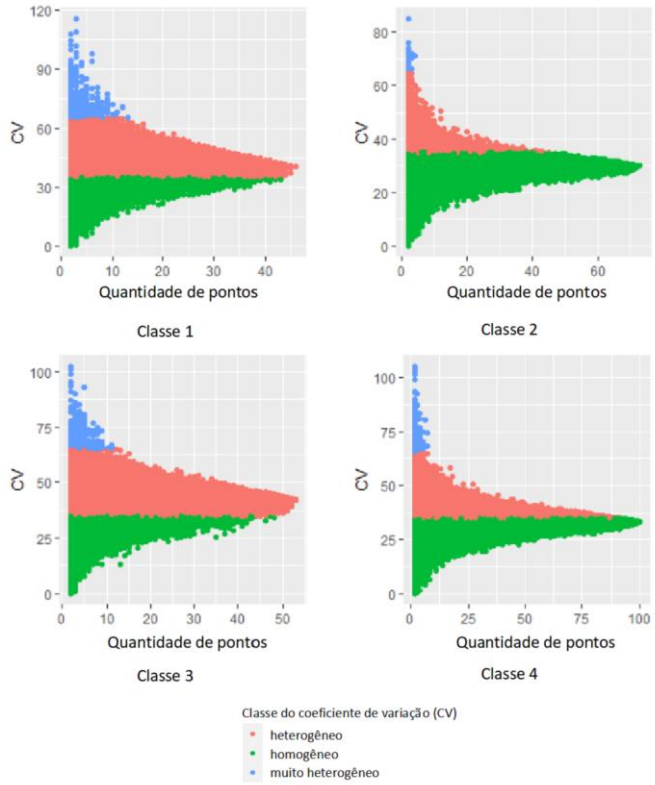


FIGURA 6: gráfico de comparação de Coeficiente de Variação (CV) de potássio (K) nas classes 1, 2, 3 e 4 em relação a quantidade de pontos coletados em campo.

Quando o CV foi calculado com todas as subamostras disponíveis (CV de referência), o valor obtido fora classificado como homogêneo, heterogêneo ou muito heterogêneo. Quando o cálculo do CV fora realizado usando menos subamostras (e que neste trabalho, os cálculos foram obtidos de 1000 simulações de amostragem), houve duas possibilidades: a do CV receber a mesma classificação do CV de referência (isto é, houve a "sorte" daquele número de subamostras levar a um CV com mesma classificação da referência); ou a possibilidade do CV receber uma classificação distinta a do CV de referência (isto é, houve o "azar" daquele número de subamostras levar a CV com classificação distinta a da referência). Por exemplo na classe 1 para manejo do K: é possível que "devido à sorte", a coleta de 5 subamostras leve a um CV com mesma classificação do CV obtido com 46 amostras que é o total de amostras para a classe 1 e que é considerado como referência; no entanto também é possível que "devido ao azar", as 5 subamostras coletadas levem a um CV diferente do CV calculado com as 46 amostras.

A Figura 7 apresenta os valores da probabilidade dos coeficientes de variação dos atributos fósforo e potássio, calculados com o uso de diferentes quantidades de pontos amostrais, serem classificados na mesma categoria da referência. Nota-se que há tendência da probabilidade aumentar conforme aumenta-se o número de amostras para calcular a média e o CV dos atributos fósforo e potássio. Ou seja, quanto mais amostras forem coletadas, maior é a probabilidade de fugir daquele jogo de sorte/azar.

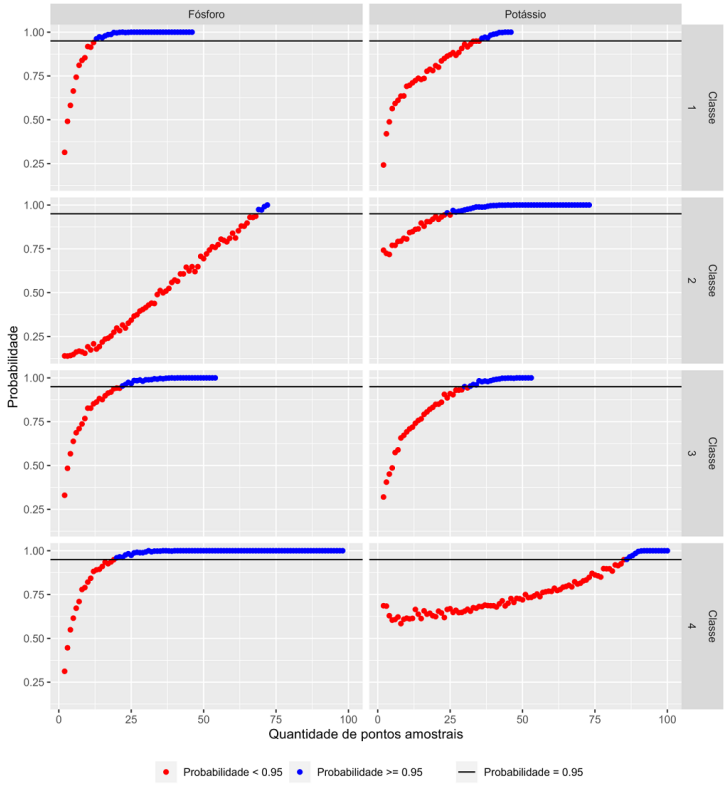


FIGURA 7: probabilidade dos coeficientes de variação dos dados do fósforo e potássio calculados com diferentes quantidades de pontos amostrais receberem a mesma classificação da referência.

Para o fósforo, o número mínimo de amostras que representariam a maioria das classes (por meio da concordância com a referência) fica na faixa de 13 a 22, já no caso do potássio, a faixa é de 26 a 36 (Tabela 3). Apenas com a exceção em dois casos: a classe 2 do fósforo e a classe 4 do potássio que indicam uma necessidade de ao menos 69 e 86 amostras para que o coeficiente de variação dos dados de fósforo e potássio, respectivamente, corresponda a um nível similar ao da referência ao nível de 95% de probabilidade.

TABELA 3: Número mínimo de amostras para os atributos químicos fósforo (P) e potássio (K) em relação a convergência em uma única classificação de CV

Classe da zona de manejo	Atributo Químico	N° mínimo de amostras*	Faixa de classificação do CV	Total de amostras em cada classe das zonas de manejo	N° mínimo de amostras/Total de amostras em cada classe (%)
1	P	13	heterogêneo	46	28,3
2	P	68	heterogêneo	72	94,4
3	P	22	heterogêneo	54	40,7
4	P	20	heterogêneo	98	20,4
1	K	36	heterogêneo	46	78,3
2	K	26	homogêneo	73	35,6
3	K	32	heterogêneo	53	60,4
4	K	86	homogêneo	100	86,0

* ao nível de 95% de probabilidade

Para o atributo potássio, o número mínimo de amostras em relação ao total coletado em cada classe superou os 50% nas classes 1, 3 e 4. Apenas na classe 2 foi necessário utilizar uma quantidade abaixo de 50% do total de amostras nesta classe para que o CV calculado convergisse para a mesma categoria da referência. Já para o atributo fósforo, na maioria das classes (1, 3 e 4), ao utilizar menos de 41% das amostras totais inseridas nas respectivas classes, já foi suficiente para que a categoria do CV convergisse para a mesma categoria de referência. Na classe 2 para o atributo fósforo e na classe 4 para o atributo potássio foram necessárias a utilização de quase todas as amostras para que o CV convergisse para a mesma categoria de referência (que é aquele calculado com todas as amostras inseridas na respectiva classe).

Considerando que a utilização de quantidades baixas de amostras pode atender à maioria das classes, mas pode ser insuficiente para uma das classes (como é o caso da classe 2 e 4 para os atributos fósforo e potássio respectivamente) e para garantir uma maior representatividade do cálculo, a quantidade mínima de amostras a serem coletadas deveria ser de 68 para o fósforo e de 86 para o potássio. Na realidade, é provável que o número de amostras simples coletadas fique na faixa de 10 a 20, pois esta é uma recomendação recorrente em vários manuais e páginas na internet que o produtor rural tem acesso (MOVIMENTO AGRO, 2024; MANEJE BEM, [2022?]; JUNDIAÍ, [2021?]; COCAPEC, [s. d.]; EMBRAPA, [s. d.]; PLANTE CERTO, [s. d.]; TERRANÁLISES, [s. d.]).

CONCLUSÃO

Para a maioria dos casos, foi possível determinar a quantidade mínima de amostras simples a serem coletadas para compor uma amostra composta que representa adequadamente a classe de manejo. O número mínimo de amostras simples que representariam a maioria das classes (por meio da concordância com a referência) fica na faixa de 13 a 22 no caso do fósforo. Já no caso do potássio, a faixa é de 26 a 36 amostras simples.

AGRADECIMENTOS

Agradecemos às instituições Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), Fundação de Apoio à Pesquisa do Estado de Minas Gerais (FAPEMIG), Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e Universidade Federal Rural de Pernambuco pelo apoio.

REFERÊNCIAS

ANCHIETA, L.. **Amostragem de Solo em Agricultura de Precisão: Particularidades e recomendações**. Universidade de São Paulo, Piracicaba, 2012.

BARNETT, V.; LEWIS, T.. **Outliers in Statistical Data**, 3rd edn. Hoboken: John Wiley & Sons. 1994.

BASSOI, L. H.; INAMASU, R. Y.; BERNARDI, A. C. C.; VAZ, C. M. P.; SPERANZA, E. A.; CRUVINEL, P. E.. Agricultura de precisão e agricultura digital. **TECCOGS - Revista Digital de Tecnologias Cognitivas**, n. 20, p. 17-36, 2019.

COCAPEC. Amostragem de solo: como separar e enviar ao laboratório. Franca, [s. d.]. Disponível em: https://bit.ly/3ReZtL2. Acesso em: 07, junho de 2024.

EMBRAPA. Análise de solo: Procedimentos para coleta de amostras.Pelotas, [s. d.]. Disponível em: https://bit.ly/3x4bv37. Acesso em: 07, junho de 2024.

GEBBERS, R.; ADAMCHUK, V. I.. Precision agriculture and food security. **Science**, v. 327, n. 5967, p. 828-831, 2010.

GEORGI, C.; SPENGLER, D.; ITZEROTT, S.; KLEINSCHMIT, B.. Automatic Delineation Algorithm for site-specific management zones based on satellite remote sensing data. **Precision Agriculture**, v. 19, n. 4, p. 684-707, 2018.

JUNDIAÍ. Como realizar a coleta de amostras de solo. Jundiaí, [2021?]. Disponível em: https://bit.ly/4c5Szj6. Acesso em: 07, junho de 2024.

MANEJE BEM. Manual de Coleta de Solo para Análise Química e Física: Parte 1. [2022?]. Disponível em: https://bit.ly/45fnW8K. Acesso em: 07, junho de 2024.

MOLIN, J. P.; BAZAME, H. C.; MALDANER, L.; CORREDO, L. P.; MARTELLO, M.; CANATA, T. F.. Precision agriculture and the digital contributions for site-specific management of the Fields. **Revista Ciência Agronômica**, v. 5, n. spe, 2020.

MOVIMENTO AGRO. Porque fazer Amostragem de Solo?. Luz, 2024. Disponível em: https://bit.ly/3KBdmzm. Acesso em: 07, junho de 2024.

NOGUEIRA, M. C. S.. **Experimentação agronômica I: conceitos, planejamento e análise estatística**. Universidade de São Paulo, Piracicaba, 2007.

PLANTE CERTO. Amostragem de Solo. [s. d.]. Disponível em: https://bit.ly/3VxtwQD. Acesso em: 07, junho de 2024.

QGIS [software GIS]. Versão 3.16.10. QGIS Geographic Information System. Open Source Geospatial Foundation Project. http://qgis.osgeo.org, 2021.

ROSA, H. A.. Sensoriamento Remoto Orbital e não Orbital no Delineament de Zonas de Manejo para Agricultura de Precisão. Universidade Estadual do Oeste do Paraná, Cascavél - PR, 2021.

SARTORI, A. A. C.. Geoestatística multivariada na delimitação de zonas de manejo na cultura de cana-de-açúcar. Universidade Estadual Paulista Júlio de Mesquita Filho, Botucatu, 2014.

TAN, B.; MASEK, J. G.; WOLFE, R.; GAO, F.; HUANG, C.; VERMOTE, E. F.; SEXTON, J. O.; EDERER, G.. Improved forest change detection with terrain illumination corrected Landsat images. **Remote Sensing of Environment**, v. 136, p. 469-483, 2013.

TAN, B.; WOLFE, R.; MASEK, J.; GAO, F.; VERMOTE, E. F.. An illumination correction algorithm on Landsat-TM data. In: 2010 IEEE International Geoscience and Remote Sensing Symposium. IEEE, 2010.

TEAM, R. Core et al. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, 2021.

YAMAMOTO, J. K.; LANDIM, P. M. B.. **Geoestatística: conceitos e aplicações**. 1ª reimpressão. São Paulo: Oficina de Textos, 2015.

SENSORIAMENTO DE VIBRAÇÃO DE ABELHAS SEM FERRÃO: UM ESTUDO EXLORATÓRIO

FELIPE JUCÁ DOS SANTOS [1]; Isac Gabriel Abrahão Bomfim [2]; Marcelo Casimiro Cavalcante [3]; Alexandre Augusto da Penha Coelho [4]; Danielo Gonçalves Gomes [4]

[1]ALUNO DE DOUTORADO (BOLSISTA). Av. Mister Hull, s/n - Pici - CEP 60455-760 - Fortaleza - CE. UNIVERSIDADE FEDERAL DO CEARÁ; [2]ZOOTECNISTA. Av. Dr. Geraldo Barbosa Marques, 567 - Venancio, Crateús - CE - CEP: 63708-260. Instituto Federal de Educação, Ciência e Tecnologia do Ceará | Campus Crateús; [3]PROFESSOR. R. José Franco de Oliveira, s/n - Zona Rural, Redenção - CE - CEP: 62790-970. Universidade da Integração Internacional da Lusofonia Afro-Brasileira | Campus das Auroras; [4]PROFESSOR. Av. Mister Hull, s/n - Pici - CEP 60455-760 - Fortaleza - CE. UNIVERSIDADE FEDERAL DO CEARÁ

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

O objetivo deste estudo foi identificar anomalias nos padrões de comportamento acústico dentro do ninho de colônias da abelha sem ferrão *Scaptotrigona* aff. *depilis*, conhecida popularmente como abelha canudo, submetidas a uma invasão por outra espécie de abelha. Para a coleta dos dados, foi desenvolvido um hardware que utiliza um sensor piezoelétrico controlado por um microcontrolador Arduino. O sensor foi posicionado internamente na caixa racional, na parede oposta ao orifício de entrada das abelhas. A coleta de dados ocorreu no período da manhã, no Meliponário da Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB), Ceará, com duração de uma hora e uma taxa de aproximadamente 100 leituras por segundo. A espécie invasora utilizada foi a abelha marmelada (*Frieseomelitta varia*). Observamos variações na amplitude e na frequência do sinal durante a invasão, devido ao deslocamento de um grande número de operárias da colônia para a entrada da caixa racional, ou seja, para o lado oposto onde o sensor estava fixado. Os achados deste estudo podem ser úteis aos meliponicultores, permitindo-lhes reconhecer precocemente os padrões de perturbação de uma colônia sob invasão e realizar intervenções imediatas para resolver o problema. Por fim, este trabalho abre uma janela para investigações sobre o comportamento de comunicação acústica intranidal em abelhas sem ferrão, utilizando um método prático, minimamente invasivo e economicamente acessível.

PALAVRAS-CHAVE: SENSORIAMENTO; VIBRAÇÃO; Scaptotrigona aff. Depilis

ABSTRACT

The objective of this study was to identify anomalies in the acoustic behavior patterns within the nest of colonies of the stingless bee *Scaptotrigona* aff. *depilis*, commonly known as the "canudo" bee, subjected to an invasion by another bee species. For data collection, a hardware system was developed using a piezoelectric sensor controlled by an Arduino microcontroller. The sensor was positioned internally in the rational box, on the wall opposite the bees' entrance hole. Data collection took place in the morning at the Meliponary of the Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB), Ceará, lasting one hour with a rate of approximately 100 readings per second. The invading species used was the "marmelada" bee (*Frieseomelitta varia*). We observed variations in the amplitude and frequency of the signal during the invasion due to the displacement of a large number of worker bees to the entrance of the rational box, which is the side opposite where the sensor was fixed. The findings of this study can be useful to meliponiculturists by allowing them to recognize early the disturbance patterns of a colony under invasion and to take immediate action to solve the problem. Finally, this work opens a window for investigations into the intranidal acoustic communication behavior of stingless bees using a practical, minimally invasive, and economically accessible method.

KEYWORDS: Sensing; Sensing; *Scaptotrigona* aff. *depilis*

INTRODUÇÃO

A comunicação animal é um comportamento que envolve sinais que tem como função transportar informações de um emissor a um ou mais receptores (NAGUIB, 2006). Particularmente, em se tratando de abelhas sociais, essa comunicação é realizada, principalmente, pela emissão de feromônios (sinais químicos), bem como por sinais acústicos, sendo este último gerado, majoritariamente, pela vibração dos músculos torácicos desses insetos (KIRCHNER, 1993). A comunicação por sinais acústicos pode ser dividida em dois tipos: por sinais de vibração transmitidos pelo ar ou pelo substrato, sendo a última conhecida por tremologia ou biotremologia (HILL; WESSEL, 2016).

Esses sinais podem provocar diversos tipos de comportamento nos indivíduos da colônia tanto dentro como fora do ninho. Por meio deles, é possível identificar ou até mesmo prever, a presença da rainha, a enxameação, bem como o estado de saúde e o recrutamento para forrageamento e a defesa da colônia (KIRCHNER, 1993; KRAUSA et al., 2017; KRAUSA; HAGER; KIRCHNER, 2021; QANDOUR et al., 2014). Então, de maneira não invasiva, identificar ou mesmo prever esses comportamentos pode auxiliar o criador de abelhas a realizar intervenções em tempo hábil a fim de reduzir as consequências causadas pelas condições indesejadas (AUMANN; AUMANN; EMANETOGLU, 2021; UTHOFF; HOMSI; VON BERGEN, 2023).

Apesar de ser um campo de estudo promissor para a apicultura de precisão e que vem apresentando bons resultados, o estudo de sinais vibratórios em abelhas ainda necessita de mais investigações, como uma maior quantidade de replicações, diversificação de experimentos, maiores amostras, horários de coletas distintos e aplicados a diversas espécies (UTHOFF; HOMSI; VON BERGEN, 2023). Além disso, estudos de biotremologia intranidal são ainda mais escassos quando se trata de espécies de abelhas sem ferrão (meliponíneos) (HRNCIR MICHAELAND BARTH, 2014; KRAUSA et al., 2017; NIEH, 2004). Somado a isso, percebe-se que esse tipo de comunicação tem sido mais estudada no contexto de forrageamento, e que pouco ainda se sabe sobre a comunicação no contexto da defesa da colônia (KRAUSA; HAGER; KIRCHNER, 2021).

Neste estudo exploratório, coletamos e analisamos dados obtidos por meio do sensoriamento de uma colônia de meliponíneo da espécie *Scaptotrigona* aff. *depilis*, popularmente conhecida como abelha canudo, que tem como características possuir colônias populosas e operárias defensivas no ninho, capazes de voar e morder invasores, na tentativa de impedir a entrada de seres estranhos na colônia (FARIA et al., 2012).

OBJETIVOS

Diante do contexto apresentado, aqui tivemos o objetivo de identificar anomalias nos padrões de comportamento acústico dentro do ninho de uma colônia da espécie canudo (*Scaptotrigona* aff. *depilis*), submetidas a uma invasão por outra espécie de abelha.

MATERIAL E MÉTODOS

Foram formuladas as seguintes hipóteses para este estudo:

Hipótese Nula (H0): Não há anomalias perceptíveis nos padrões de comportamento acústico dentro do ninho de uma colônia da espécie *Scaptotrigona* aff. *depilis* quando submetidas a uma invasão por outra espécie de abelha.

Hipótese Alternativa (H1): Há anomalias perceptíveis nos padrões de comportamento acústico dentro do ninho de uma colônia da espécie *Scaptotrigona* aff. *depilis* quando submetidas a uma invasão por outra espécie de abelha.

Para testar estas hipóteses, o estudo foi delineado a partir do seguinte design experimental a seguir:

A concepção deste trabalho parte da confecção de um sistema de sensoriamento de vibração que utiliza um sensor piezoelétrico para captar os sinais provenientes da vibração da colônia dentro da caixa racional. Esse sistema foi desenvolvido baseado no trabalho de AUMANN, AUMANN e EMANETOGLU (2021), no qual foi proposto para o sensoriamento da espécie abelha melífera (*Apis mellifera*). Vale ressaltar que, em nosso estudo, este sistema foi adaptado para as necessidades do sensoriamento de uma espécie de meliponíneo, cuja caixa racional, embora seja feita de madeira, tem dimensões e volume bem menores do que as colmeias normalmente utilizadas para as abelhas melíferas.

O sensor piezoelétrico é composto por um transdutor eletrônico capaz de gerar uma tensão quando é fisicamente deflexionado por uma vibração, por onda sonora ou por tensão mecânica, como mostrado na Figura 1. A tensão de saída varia proporcionalmente de acordo com a pressão exercida sobre o transdutor e, diferentemente de um sensor digital que acusa somente níveis alto ou baixo, o transdutor piezoelétrico é capaz de informar a extensão da vibração detectada, ou seja, além da frequência, é possível obter a amplitude do sinal gerado.



FIGURA 1. Ilustração do funcionamento do transdutor piezoelétrico para detecção do sinal de vibração das abelhas.

Em comparação com o uso de microfones para o sensoriamento de colmeias, o sensor piezoelétrico pode ser fixado tanto na parede interna quanto na parede externa de uma caixa racional. Nesse sentido, o sensor piezoelétrico pode ser mais adequado para coletas de longo prazo, pois um microfone representaria um corpo estranho para a colônia, que tenderia a propolizar a cápsula do equipamento, fato esse que iria comprometer a qualidade do sinal coletado. Ainda que o piezo também represente um corpo estranho, pode-se protegê-lo das abelhas, envolvendo-o com uma malha de arame, sem que ocorra nenhuma descaracterização das propriedades do sensor. Assim, ele protegido e fixado na parede interna da caixa racional, continua recebendo as ondas por meio da reverberação do sinal através da madeira da dela (princípio semelhante ao que ocorre nos violões).

Quanto às coletas remotas, a quantidade de informação que é gerada pelo sinal em um piezo é muito menor do que a informação gerada por um microfone para gerar um arquivo ".WAV", por exemplo. Isso impacta diretamente na forma como os dados são armazenados ou extraídos. Em geral, os meliponários e apiários ficam localizados em áreas com pouco ou nenhum suporte energético, o que requer que os sistemas de sensoriamento remoto sejam alimentados por baterias ou energia solar. Nesse contexto, utilizar protocolos de transmissão com longo alcance e baixo consumo energético, como o LoRa (acrônimo de Long Range, do inglês, Longo Alcance) por exemplo, representa uma alternativa mais eficiente, porém inviabiliza o uso de microfones, favorecendo o uso do piezo.

As operárias da espécie de abelha canudo possuem tamanho consideravelmente menor comparado às das abelhas melíferas (6 mm x 13 mm, aproximadamente), fato esse que provocou a necessidade de se ter um amplificador de sinal ajustado em 60 dB. O amplificador escolhido foi o circuito MAX9814, que opera o ajuste de ganho para 40 dB, 50 dB ou 60 dB, possibilitando realizar testes para definir um melhor ajuste para cada necessidade. A Figura 2 apresenta um diagrama de blocos que ilustra o sistema de coleta.

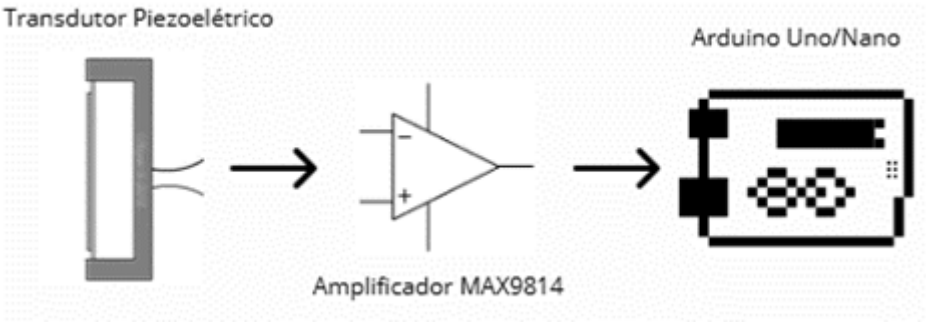


FIGURA 2. Ilustração do diagrama de blocos dos elementos principais do sistema (sensor piezoelétrico, amplificador e Arduino).

Outra diferença considerável entre sensoriar estas duas espécies de abelha é quanto às suas caixas racionais. As colmeias, nome dado às caixas racionais onde vivem as abelhas melíferas, como previamente mencionado, são maiores do que as da canudo, possuindo cerca de 42 L, enquanto a caixa racional de canudo modelo INPA possui volume aproximado de 4,0 L. Além disso, a primeira concentra sua produção de crias e alimento em favos dispostos verticalmente em quadros vazados feitos de madeira, enquanto a segunda tem suas crias agrupadas em forma de discos sobrepostos, geralmente circundada por potes onde são estocados as reservas de alimento (Figura 3A). Essas diferenças influenciam diretamente na forma de captação do sinal. Portanto, utilizamos um sensor piezoelétrico fixado na parede interna da caixa racional (Figura 3B).



FIGURA 3. A. Visão interna da caixa racional destacando a constituição do ninho da abelha canudo (*Scaptotrigona* aff. *depilis*) com sua área de cria e de reserva de alimento; B. Sensor piezo elétrico fixado à parede interna, oposta à entrada da caixa racional.

O sistema montado era controlado por um microcontrolador Arduino que coleta os dados tanto em tempo real, diretamente no computador, quanto em um módulo micro SD, para coletas remotas e de longo prazo. Em Arduinos baseados em microcontroladores AVR, como o utilizado neste trabalho, leva-se aproximadamente 100 microssegundos para se ler um valor analógico. Ou seja, é possível realizar aproximadamente 10 mil leituras por segundo. Entretanto, o Arduino é padronizado com um *baud rate* de 9.600, ou seja, neste trabalho a coleta foi realizada com aproximadamente 100 leituras a cada segundo. A Figura 4, mostra um protótipo do sistema que foi utilizado para a coleta de dados.



FIGURA 4. Imagem real do sistema utilizado para a coleta de dados fixado a uma caixa racional teste vazia (mesmo modelo utilizado nas coletas).

Como características geral do objeto de estudo temos que, o experimento conduzido analisou, de forma minimamente invasiva, o sinal gerado pela vibração de uma colônia da espécie canudo, com atividade forte, com presença de rainha (confirmado visualmente) e em seu estado normal. Em seguida, comparou-se o sinal gerado pela vibração da mesma colônia em uma situação diferente, sob tentativa de invasão de abelhas da espécie *Frieseomelitta varia*, popularmente conhecida como marmelada.

Para simular esse ataque, as caixas racionais de ambas as espécies de abelhas tiveram suas posições trocadas. As operárias da abelha marmelada, que naturalmente estavam habituadas com suas rotas de voo, tentaram regressar ao seu ninho. No entanto, ao chegarem ao local, depararam-se com o ninho da abelha canudo, cujas operárias guardas protegiam a entrada. Essa estratégia provocou uma forte reação de defesa por parte da colônia da abelha canudo contra a invasão da abelha marmelada, como mostrado na Figura 5.



FIGURA 5. Operárias da abelha marmelada (*Frieseomelitta varia*) destacadas nos círculos vermelhos tentando entrar no ninho da abelha canudo (*Scaptotrigona* aff. *depilis*) protegido pelas suas operárias guardas no tubo de entrada da caixa racional.

Ambas as coletas tiveram duração aproximada de 1 hora, no período da manhã e foram realizadas no Meliponário da Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB), *Campus* das Auroras, no município de Redenção, estado do Ceará.

RESULTADOS E DISCUSSÃO

A primeira consideração a ser feita é quanto a viabilidade do uso do sensor piezoelétrico para coletas de dados de sinais de vibração transmitidos por substratos em meliponíneos, assim como já havia sido demonstrada a sua eficácia para a abelha melífera (AUMANN; AUMANN; EMANETOGLU, 2021). O piezo se mostrou viável para coletas de longo prazo, pois gerou uma pequena quantidade de dados (aproximadamente 1 kB de dados por segundo), porém suficiente para realizar as análises. Vale ressaltar que as coletas foram feitas de forma contínua e que quando forem realizadas por um prazo mais longo, haverá intervalos periódicos para coletar os dados. Assim, a quantidade de informação necessária a ser dada vazão continuará sendo relativamente pequena.

Outro fator de viabilidade foi quanto a preservação das propriedades físicas do sensor, pois mesmo com a percepção de um corpo estranho por parte das abelhas, a aquisição do sinal não foi

comprometida pela propolização realizada por elas, indicando que mesmo em coletas de longos períodos, a qualidade do sinal será preservada sem a necessidade de maiores intervenções na caixa racional, reduzindo o estresse gerado na colônia. Comparado ao uso de microfone para coleta de dados, tem-se que com o tempo, o microfone acaba ficando coberto de própolis, o que o torna menos eficaz (AUMANN; AUMANN; EMANETOGLU, 2021).

Durante a análise dos dados coletados, nossa primeira observação concentrou-se na amplitude do sinal. Notamos que essa amplitude apresentou uma redução significativa quando a caixa racional das abelhas canudo estava sendo invadida. Esse achado sugere que as abelhas canudo, ao perceberem a invasão de seu ninho, se aglomeraram próximo ao orifício de entrada da caixa racional, ou seja, do lado oposto do local onde o sensor estava fixado, o que justificaria a redução da amplitude captada pelo sensor. Essa aglomeração seria justificada pela tentativa de defesa da colônia contra seres estranhos à colônia, o que é uma característica geral dos meliponíneos, bem como dessa espécie em estudo (FARIA et al., 2012; NUNES et al., 2014). Além disso, KRAUSA, HAGER e KIRCHNER (2021) afirmam que o padrão do sinal vibratório no contexto de defesa do ninho difere do padrão no contexto do forrageamento. Esses autores nomearam as vibrações produzidas neste contexto como "vibrações de guarda" e acreditam que esses sinais devem se direcionar aos intrusos, companheiros de ninho ou ambos. A Figura 6 apresenta uma comparação de uma amostra dos sinais coletados com a colônia em estado normal e com a colônia sob invasão de uma espécie diferente.

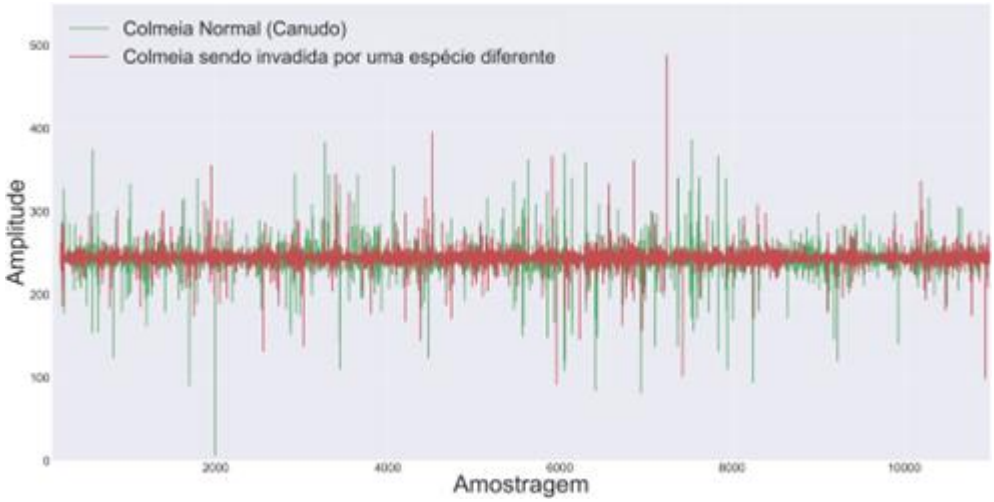


FIGURA 6. Comparação da amplitude do sinal para as coletas da colônia em estado normal (em verde) e da colônia sob invasão (em vermelho).

Ao gerarmos um espectrograma para realizar a comparação entre os sinais, percebemos que quando as abelhas canudo estavam sob invasão, a magnitude na região aproximada dos 50 Hz era mais intensa, o que pode representar um aumento da frequência nessa situação. NUNES et al. (2014) relatam uma intensa vibração e um som de zumbido alto em abelhas sem ferrão quando estão com seus ninhos sob invasão. Outra observação importante extraída do espectrograma é quanto a amplitude do sinal. Quando a colônia estava sob invasão a intensidade da amplitude do sinal é levemente menor que a amplitude da colônia em estado normal, ratificando as informações a respeito do comportamento defensivo da espécie. A Figura 7 mostra um comparativo com os espectrogramas para as duas coletas realizadas.

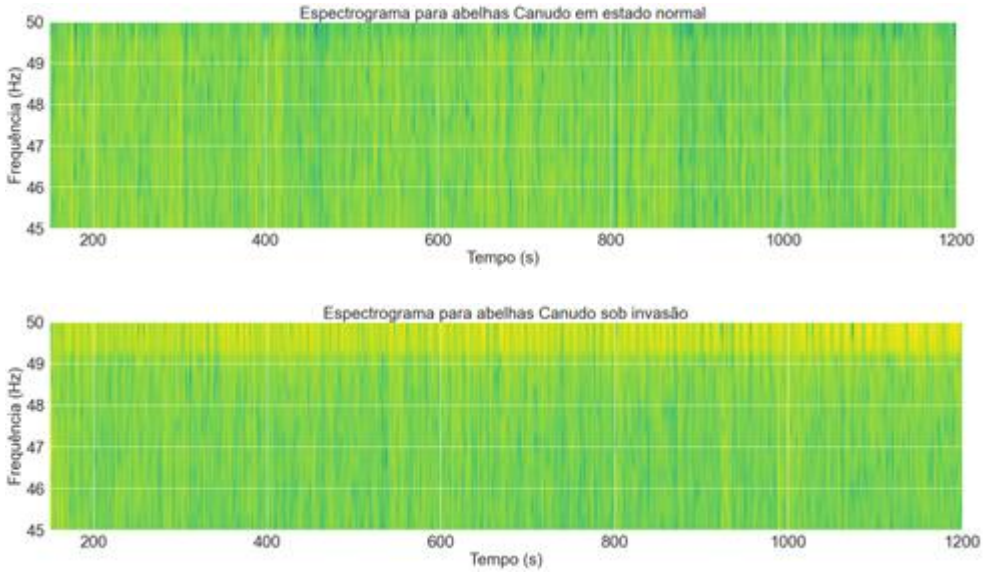


FIGURA 7. Comparação dos espectrogramas para os sinais da colônia em estado normal e sob invasão.

Em relação à quantidade e ao posicionamento dos sensores, é possível que o mesmo evento seja percebido de maneiras diferentes, dependendo da região da caixa racional onde o sensor está fixado. KRAUSA, HAGER e KIRCHNER (2021) demonstraram que os padrões de sinal da mesma espécie variam conforme o local de captação. Assim, uma abordagem potencial é a utilização de múltiplos sensores em uma única caixa racional, posicionando-os em regiões estratégicas, como nas proximidades do centro da colônia e perto do orifício de entrada da caixa racional.

A respeito do *baud rate* do Arduino, verificamos que o valor padrão de 9.600 pode ser alterado para 230.400, pois nesse valor, é possível armazenar aproximadamente 10 mil leituras a cada segundo, utilizando a capacidade máxima de leitura do Arduino, fornecendo dados com uma resolução ainda melhor e apresentando mais detalhes do sinal obtido.

Um outro ponto a ser levado em consideração neste estudo é em relação ao custo de confecção do sistema. Os componentes utilizados apresentam baixo custo de aquisição em relação a outros sistemas de sensoriamento aplicados na apicultura de precisão. A possibilidade de reprogramação do microcontrolador também permite que o sistema seja customizável e possa ser adaptado a outras espécies de meliponíneos. Reduzir custos e tornar o sistema adaptável, favorece a aquisição por parte de meliponicultores com menor poder aquisitivo, possibilitando que a meliponicultura de precisão esteja presente em um número cada vez maior de meliponários.

Vale ressaltar que o tipo de dado obtido por meio desta coleta, envolvendo a vibração produzida por abelhas sem ferrão, é escasso na literatura e pode resultar em novas perspectivas no campo da meliponicultura de precisão, apresentando alternativas para o sensoriamento e manejo dessas espécies. Essas anomalias indicam variações no comportamento da colônia dentro de sua caixa racional e, a partir disso, é possível utilizar estas informações para alertar o meliponicultor e direcionar o manejo adequado para resolver o problema, bem como auxiliar no desenvolvimento de modelos de aprendizagem de máquina que automatizem a detecção de anomalias e reduzam a necessidade de intervenção nas caixas racionais.

Para trabalhos futuros, pretendemos aumentar as amostras, realizar coletas de longo prazo, em horários diversificados, além de coletar dados de outras espécies e experimentar novas intervenções que possam ocasionar mudanças no comportamento da colônia. Diante de uma maior quantidade de informações se pretende desenvolver modelos de aprendizagem de máquina que auxiliem na análise

dos dados, contribuindo na construção de um novo método de sensoriamento de colônias de abelhas sem ferrão, dessa forma, fomentando a meliponicultura de precisão.

CONCLUSÃO

Concluímos que há anomalias perceptíveis nos padrões vibratórios de defesa em uma colônia de abelha sem ferrão da espécie canudo (*S.* aff. *depilis*), quando sujeitas à tentativa de invasão, e é viável identifica-las por meio do uso do sensor piezoelétrico, um instrumento minimamente invasivo. Assim, este trabalho abre janela para investigações sobre o comportamento de comunicação acústica intranidal em abelhas sem ferrão, utilizando um métodos prático, minimamente invasivo e economicamente acessível.

AGRADECIMENTOS

Este estudo foi financiado em parte pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código Financeiro 001. Danielo G. Gomes agradece ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela bolsa de produtividade (processo 311845/2022-3). Os autores também agradecem o apoio financeiro da FUNCAP (Fundação Cearense de Apoio à Pesquisa).

REFERÊNCIAS

AUMANN, H. M.; AUMANN, M. K.; EMANETOGLU, N. W. Janus: A Combined Radar and Vibration Sensor for Beehive Monitoring. **IEEE Sensors Letters**, v. 5, n. 3, p. 1-4, mar. 2021.

FARIA, L. B. DE et al. Foraging of *Scaptotrigona* aff. *depilis* (Hymenoptera, Apidae) in an urbanized area: Seasonality in resource availability and visited plants. **Psyche (London)**, 2012.

HILL, P. S. M.; WESSEL, A. Biotremology. **Current Biology**, v. 26, n. 5, p. R187-R191, 2016.

HRNCIR MICHAEL AND BARTH, F. G. Vibratory Communication in Stingless Bees (Meliponini): The Challenge of Interpreting the Signals. Em: **Studying Vibrational Communication**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2014. p. 349-374.

KIRCHNER, W. H. Acoustical communication in honeybees. **Apidologie**, v. 24, n. 3, p. 297-307, 1993.

KRAUSA, K. et al. Vibrational signals of African stingless bees. **Insectes Sociaux**, v. 64, n. 3, p. 415-424, 1 ago. 2017.

KRAUSA, K.; HAGER, F. A.; KIRCHNER, W. H. Guarding Vibrations-*Axestotrigona ferruginea* Produces Vibrations When Encountering Non-Nestmates. **Insects**, v. 12, n. 5, p. 395, 29 abr. 2021.

NAGUIB, M. Animal Communication: Overview. Em: **Encyclopedia of Language & Linguistics**. [s.l: s.n.]. p. 276-284.

NIEH, J. C. Recruitment communication in stingless bees (Hymenoptera, Apidae, Meliponini). **Apidologie**, v. 35, n. 2, p. 159-182, mar. 2004.

NUNES, T. M. et al. Defensive repertoire of the stingless bee *Melipona flavolineata* Friese (Hymenoptera: Apidae). **Sociobiology**, v. 61, n. 4, 29 dez. 2014.

QANDOUR, A. et al. Remote Beehive Monitoring using Acoustic Signals. **Acoustics Australia / Australian Acoustical Society**, v. 42, p. 204-209, maio 2014.

UTHOFF, C.; HOMSI, M. N.; VON BERGEN, M. Acoustic and vibration monitoring of honeybee colonies for beekeeping-relevant aspects of presence of queen bee and swarming. **Computers and Electronics in Agriculture**, v. 205, p. 107589, fev. 2023.

DEFINIÇÃO DE UNIDADES DE GESTÃO DIFERENCIADAS PARA A VITIVINICULTURA

GABRIEL ROCHA DE SOUZA [1]; JÚLIA FACCIN FAÉ [2]; ANTÔNIO LUÍS SANTI [3]; GILMAR ARDUINO BETTIO MARODIN [4]; ANDRÉ LUIS VIAN [5]

[1]Graduando. Porto Alegre - RS. Universidade Federal do Rio Grande do Sul; [2]Mestre em Fitotecnia. Porto Alegre - RS. Universidade Federal do Rio Grande do Sul; [3]Docente. Santa Maria - RS. Universidade Federal de Santa Maria; [4]Docente. Porto Alegre - RS. Universidade Federal do Rio Grande do Sul; [5]Docente. Porto Alegre - RS. Universidade Federal do Rio Grande do Sul

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

O objetivo deste trabalho foi utilizar o Índice de Vegetação por Diferença Normalizada (NDVI) para definição de unidades de gestão diferenciadas (UGDs) como uma forma de entendimento da gestão da variabilidade espacial do vinhedo. Para realização do estudo foram utilizadas duas quadras em um vinhedo comercial, das variedades de Merlot e Chardonnay, onde foi determinado três UGDs (alto, médio e baixo vigor) baseadas na média de sete mapas de NDVI ao longo de dois anos, em diferentes momentos durante o ciclo da videira. Foram analisados dados de duas safras, referentes a produtividade e qualidade da uva em 15 pontos amostrais distribuídos por três UGDs. Os resultados indicam que o NDVI pode ser usado para delimitar UGDs, pois foi possível verificar variações de vigor dentro do vinhedo e que parâmetros de solo são os que mais influenciam na variabilidade, podendo ser utilizados para a validação a campo e adequação de manejos para a melhor gestão intraespecífica do vinhedo.

PALAVRAS-CHAVE: *Vitis vinifera*; vitivinicultura de precisão; manejo localizado

ABSTRACT

The objective of this work was to use the Normalized Difference Vegetation Index (NDVI) to define differentiated management units (UGDs) as a way of understanding the management of spatial variability in the vineyard. To carry out the study, two blocks were used in a commercial vineyard, of Merlot and Chardonnay varieties, where three UGDs (high, medium and low vigor) were determined based on the average of seven NDVI maps over two years, at different times. during the vine cycle. Data from two harvests were analyzed, referring to grape productivity and quality in 15 sampling points distributed across three UGDs. The results indicate that NDVI can be used to delimit UGDs, as it was possible to verify variations in vigor within the vineyard and that soil parameters are those that most influence variability, and can be used for field validation and adaptation of management for better intraspecific vineyard management.

KEYWORDS: ;

INTRODUÇÃO

A Vitivinicultura de Precisão (VP) vem sendo recentemente estudada e implementada em diversos lugares do mundo, uma vez que a compreensão da variabilidade espacial dos vinhedos a partir das ferramentas tecnológicas podem auxiliar na tomada de decisão em relação às práticas de manejo e do mapeamento da qualidade e da produtividade (TARDARGUILA et al., 2021). Umas das principais práticas é a utilização de Unidades de Gestão Diferenciada (UGD), que permitem identificar regiões homogêneas, ou seja, áreas com mínima variabilidade espacial e com consistência ao longo do tempo,

para uma melhor gestão do vinhedo visando maximizar a eficiência e reduzir impactos ambientais, o que se traduz no aumento da economia para o vitivinicultor (GIOVOS et al., 2021).

A variabilidade espacial dos vinhedos é recorrente e manifesta-se em regiões distintas dentro do vinhedo. Essas regiões se caracterizam por diferentes fatores como topografia, exposição solar, tipo e textura do solo, perfil do solo, inclinação, altitude, entre outros, que, por sua vez, conferem potenciais produtivos diversos dentro do mesmo vinhedo o (GATTI et al., 2022; PEREYRA et al., 2023).

Existem diversas formas para determinar e avaliar a variabilidade espacial na VP, proporcionadas pela combinação diversos tipos de sensores, aliados à flexibilidade das principais plataformas de aquisição, como satélites (FERRO et al., 2023; FERRO; CATANIA, 2023; SOZZI et al., 2020; SQUERI et al., 2021). O Índice de Vegetação por Diferença Normalizada (NDVI) se relaciona diretamente com o teor e concentração de clorofila nas folhas e com a biomassa do dossel vegetativo da planta é calculado a partir da diferença entre bandas espectrais do espectro eletromagnético, que são capturadas por sensores em satélites, aeronaves ou drones. Dessa forma, é uma ferramenta importante para avaliar o desenvolvimento vegetativo, além de estimar o rendimento, stress hídrico e qualidade de uva (FERRER et al., 2020; MATESE; DI GENNARO, 2021; OLDONI et al., 2020; SILVA COSTA et al., 2023).

OBJETIVOS

Os objetivos deste estudo foram definir o delineamento de UGDs através do NDVI obtido por satélite, buscando compreender como variabilidade espacial do vinhedo se comporta e quais parâmetros de solo e de planta que mais impactam na produtividade e na qualidade da uva nas UGDs para indicar melhor manejo do vinhedo.

MATERIAL E MÉTODOS

Localização e caracterização da área de estudo

O estudo foi realizado on farm nos vinhedos da vinícola Casa Ângelo Fantin, localizado no município de Monte Belo do Sul (RS), em dois vinhedos (Merlot e Chardonnay). O município situa-se na região fisiográfica da Encosta Superior do Planalto (Serra Gaúcha), região reconhecida pela produção de vinhos do Brasil. A caracterização climática é classificada como Cfb, que corresponde a um clima temperado úmido com verões amenos. A precipitação pluviométrica média anual é de 1.770 mm com distribuição média superior a 100 mm, segundo a classificação de Köppen (TONIETTO et al., 2008).

Os vinhedos utilizados (Merlot e Chardonnay) são cultivadas no sistema de condução espaldeira com 14 e 10 anos, respectivamente. As videiras foram manejadas com poda manual de cordão esporonado (Merlot) e poda Guyot duplo (Chardonnay). O vinhedo Merlot possui uma área total de 0,44 ha, com espaçamento entre linhas e plantas é de 2,50 x 1,20, totalizando 1.466 plantas. O vinhedo Chardonnay possui uma área de 0,40 ha, com espaçamento de 2,0 x 1,20 entre linhas e plantas, totalizando 1.665 videiras. Ambos vinhedos foram enxertadas sobre o porta-enxerto Paulsen 1103. As práticas culturais foram conduzidas na totalidade pelo produtor, seguindo o manejo recomendado para a cultura, sendo as podas realizadas em agosto em ambas as safras 2021/2022 e 2022/2023. Não foi realizada nenhuma adubação durante o período do experimento nos vinhedos.

Delineamento das UGDs por sensoriamento remoto

As UGDs foram delimitadas baseadas no NDVI de cada vinhedo, onde utilizou-se sete (7) mapas de NDVI entre os anos de 2020 e 2021. Os valores de NDVI foram obtidos de diferentes períodos do

ciclo do vinhedo, ou seja, distintos estádios de desenvolvimento da videira: dormência da videira, brotação da videira, floração da videira e maturação da videira.

Os valores de NDVI foram obtidos com o auxílio da plataforma Auravant®, que utiliza imagens de satélites com resolução espacial de 3 m x 3 m, totalizando 9m2, sendo as imagens obtidas pelos satélites da Constelação Planet®. Considerando a variabilidade espacial existente, definiram-se diferentes UGDs para cada vinhedo, sendo classificadas em baixo, médio e alto vigor (Tabela 1).

TABELA 1. Valores médios de NDVI utilizados para definir as unidades de gestão diferenciadas (UGDs) nos vinhedos estudados.

UGDs	Merlot	Chardonnay
Alto Vigor (AV)	0,73 a 0,81	0,70 a 0,79
Médio Vigor (MV)	0,65 a 0,72	0,61 a 0,69
Baixo Vigor (BV)	0,55 a 0,64	0,51 a 0,60

UGDs - unidades de gestão diferenciadas.

Em cada uma das UGD foram distribuídos cinco pontos amostrais, onde cada ponto amostral foi composto por cinco plantas escolhidas 4 plantas ao redor da planta central, assim cada vinhedo foi composto por 15 pontos amostrais no total.

Verifica-se que a variabilidade de NDVI existente nos vinhedos ao longo dos períodos avaliados realizou-se a construção de UGDs por meio da interpolação dos valores de NDVI através da plataforma Auravant®. Nas Figuras 1A e 1B, são apresentados os sete mapas de NDVI utilizados para a criação das UGDs e o último mapa são apresentadas as três UGDs nas quais os cinco pontos amostrais foram distribuídos em cada UGD para a coleta das análises de planta, solo e mosto da uva.

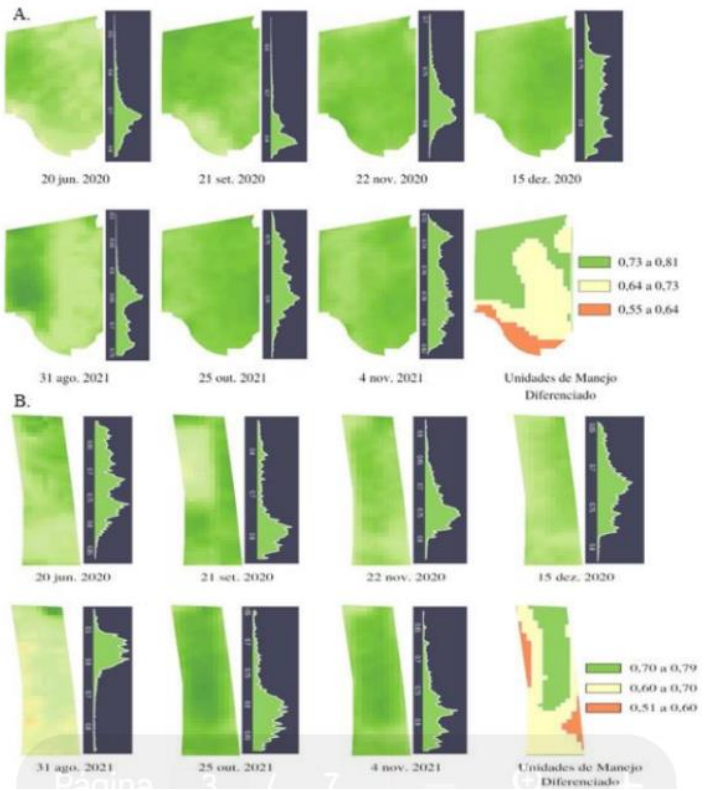


FIGURA 1. Sete mapas de NDVI e seus respectivos histogramas ao longo do ciclo da videira e o mapa das UGDs segundo classificação dos valores médios de NDVI da quadra Merlot (A) e Chardonnay (B).

Parâmetros dos atributos físico-químicos do solo, planta e mosto

Os parâmetros analisados foram: química do solo (camada 0 - 0,20 m), produção da uva (kg ha^{-1}), número de cachos por planta, número de ramos por planta e qualidade do mosto da uva (grau Brix°, Acidez Total e pH do mosto). Para a coleta das variáveis analisadas a campo, dentro dos limites georreferenciados de cada UGD foram marcados cinco pontos amostrais, totalizando 15 pontos por vinhedo e 30 pontos no total do estudo. Cada ponto amostral foi composto por uma planta principal e mais cinco plantas que foram selecionadas ao seu redor. A partir da planta principal, duas outras eram marcadas na mesma linha, intercalando uma planta a partir da central, e nas linhas laterais eram marcadas mais duas plantas paralelas a videira principal. Assim, cada vinhedo possuía um total de 75 plantas amostradas.

Análise estatística

A normalidade dos dados foi testada através do teste de Shapiro Wilk. Posteriormente, realizou-se a comparação de médias através de teste de Tukey. Os dados que não apresentaram normalidade foram analisados através do Teste de Kruskal Wallis. Dados da análise química de solo foram submetidos a análise estatística descritiva, através do software Excel. A análise exploratória multivariada de Clustering, através da média padronizada da distância euclidiana. O corte para agrupamento dos dados foi determinado através do teste de Mojena. Finalmente, a análise de componentes principais para reconhecimento das variâncias e correlações entre tratamentos e variáveis. As análises foram realizadas com o software R Studio® e com os pacotes Factoextra e Multivariete Analisys.

RESULTADOS E DISCUSSÃO

As ferramentas tecnológicas de sensoriamento remoto na VP avaliam a estrutura vegetativa e o potencial produtivo das videiras, com a premissa de que o dossel vegetativo reflete as influências do ambiente biofísico das videiras, incluindo clima, solo, doenças e pragas (FERRO; CATANIA, 2023; GIOVOS et al., 2021). Estudos recentes ressaltaram o potencial das imagens de satélite na viticultura em uma escala territorial para a obtenção de informações agronômicas, quantificação do impacto da seca e dados para análise de terroir (BRAMLEY et al., 2023; DEVAUX et al., 2019). Entretanto, a aplicação de imagens de baixa resolução, como as provenientes de satélites, na vitivinicultura de pequena escala vem sendo investigada, uma vez que apresenta desafios devido às particularidades dos vinhedos, como a diversidade de sistemas de condução e vegetação nas entrelinhas (SAMS et al., 2022; FERRER et al., 2020; GATTI et al., 2017).

Há um consenso geral de que variações na textura do solo do vinhedo, na capacidade e profundidade de retenção de água, na inclinação e aspecto do terreno são fatores cruciais que impactam a variabilidade das culturas e, consequentemente, o desempenho da videira (PEREYRA et al., 2023; GATTI et al., 2022; ECHEVERRÍA et al., 2017). Dessa forma, buscou-se caracterizar os UGDs quanto aos seus atributos químicos de solo, visando compreender qual o estado da fertilidade dos solos e sua possível influência na expressão da biomassa vegetativa capturada pelo NDVI para a definição das UGDS.

A partir dos resultados da análise de solo, em ambas UGDs de MV, o pH em água está abaixo de 5,5, valor em que a aplicação de calcário é indicada. Nos vinhedos estudados, o teor de argila, matéria orgânica (M.O) e capacidade de troca de cátions (CTC) de cada UGD apresentaram baixo CV%. As UGDs foram classificadas na categoria 3 com base no teor de argila (40 a 21%), indicando um solo franco argilo arenoso com base no triângulo de classificação textural de solos, corroborando a informação de Tonietto et al. (2008), que a maior parte dos solos localizados acima de 400m em Monte Belo do Sul, são classificados como Argissolos.

As diferenças de vigor avaliadas pelo NDVI, estão associadas ao crescimento vegetativo das videiras e ao ambiente de produção (BRAMLEY et al., 2011; JASSE et al., 2021). O ambiente de alto vigor possui um maior crescimento vegetativo (BRAMLEY et al., 2011; FERRER et al., 2020; PEREYRA et al., 2023). Por outro lado, o baixo vigor das plantas frequentemente resulta em menor crescimento vegetativo e exposição excessiva dos cachos à radiação direta, impactando na qualidade da produção (BRAMLEY et al., 2011; FERRER et al., 2020; GATTI et al., 2022). Os parâmetros de produtividade, da qualidade da uva, número de bagas, teor de açúcar (Brix), e acidez total são apresentados na Tabela 2. Observa-se que o parâmetro Brixo para o vinhedo Merlot apresentou diferença estatística entre a UGD de alto vigor, que diferiu da UGD de baixo vigor, resultados corroboram com os encontrados por (KASIMATI et al, 2023; BRAMLEY et al. 2011).

TABELA 2. Análise de variância para características de rendimento e composição vegetativa e de uva dentro das UGDs (baixo, médio e alto vigor) considerando a média das duas safras.

Chardonnay							
Unidade de Gestão Diferenciada				Parâmetros			
	Alto	Médio	Baixo	μ	AT	EMP	p-valor
Produtividade	9.734,9	9.568,3	10.784,9	10.029,3	1.216,6	424,1	0,5^{ns}
Cachos (nº)	25,8	25,1	25,8	25,5	0,6	1,8	1,0^{ns}
Ramos (nº)	19,5	20	18,6	19,4	1,4	0,6	0,6^{ns}
Cachos (g)	212,6	196,9	187	198,8	25,6	11,9	0,5^{ns}
Brix (º)	19,8	19,6	19,3	19,6	0,5	0,5	0,8^{ns}
AT (meq L^{-1})	8,5	8,2	8,8	8,5	0,6	0,3	0,7^{ns}
pH	3,4	3,4	3,4	3,4	0,0	0,0	0,9^{ns}
Merlot							
Produtividade	12.880,7	11.024,6	12.574,8	12.160,0	1.856,1	448,8	0,2^{ns}
Cachos (nº)	27,1	25,9	25,1	26,0	2,0	0,8	0,6^{ns}
Ramos (nº)	17,6	16,5	16,9	17,0	1,1	0,3	0,2^{ns}
Cachos (g)	250,8	263,1	248,8	254,2	14,4	17,1	0,9^{ns}
Brix (º)	22,5	22,1	21,3	21,9	1,2	0,2	0,03*
AT (meq L^{-1})	8,6	8,4	9,3	8,8	0,8	0,2	0,2^{ns}
pH	3,2	3,5	3,5	3,4	0,3	0,1	0,3^{ns}

*p-valor <0,05. μ – Média; AT – amplitude total; EMP – erro médio padrão.

Segundo Pereyra et al. (2022), a gestão intra-específica de vinhedos com base em zonas estabelecidas por NDVI mostrou-se capaz de potencializar áreas de alto vigor e melhorar áreas de baixo vigor, através de manejos como taxa de insumos variada, regulação da disponibilidade de água, desfolha e poda. No presente estudo, apesar da diferença entre o potencial produtivo encontrado nos vinhedos com base no NDVI, o manejo uniforme favoreceu as áreas de baixo vigor, maximizando a uma maior produção e diminuído o potencial das áreas de alto vigor, uma vez que as áreas de baixo vigor apresentaram um desempenho mais equiparado em relação às áreas de alto vigor, mostrando uma similaridade entre os dois extremos, já que as áreas de vigor moderado apresentaram valores sempre inferiores aos das outras duas UGDs.

A análise de agrupamento das variáveis coletadas nas UGD, durante as safras, revelou a existência de três grupos distintos nos dendrogramas para os vinhedos Merlot e Chardonnay (Figura 2 A e B). Os pontos coletados agruparam-se de maneira consistente com a distribuição dos pontos à campo dentro das UGDs, indicando que os agrupamentos com base nos valores médios de NDVI refletem as semelhanças e diferenças encontradas nas análises de parâmetros de solo, produtividade e qualidade do vinhedo realizadas no campo. Para o vinhedo Merlot (Figura 2 A), a UGD de alto vigor, independente das safras, agruparam-se no mesmo ambiente delimitado pelo NDVI. Da mesma forma, os demais agrupamentos seguiram o mesmo padrão, sendo as UGDs de baixo e de médio vigor.

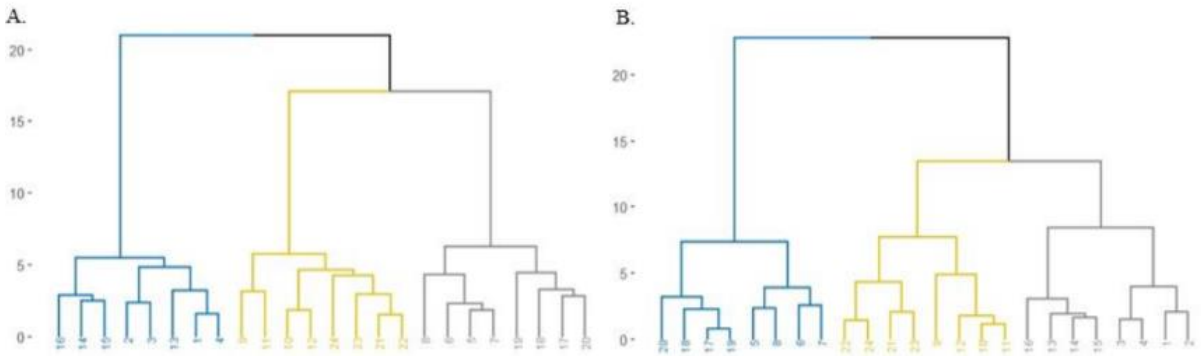


FIGURA 2. Análise de agrupamentos da produtividade, qualidade e química do solo da videira nas unidades de gestão diferenciada (UGD), para as safras estudadas para cultivar Merlot (A) e Chardonnay (B), cultivada em Monte Belo do Sul - RS. Agrupamento azul (UGD de médio vigor); Amarelo (baixo vigor) e Cinza (alto vigor).

De acordo com a análise de argumento, houve a formação de apenas dois grupos, ou seja, duas UGD de acordo com a variabilidade encontrada para ambos vinhedos estudados e em ambas as safras. Nos vinhedos Merlot e Chardonnay, as UGDs de baixo e alto vigor são mais relacionadas entre si, do que com a UGD de médio vigor, corroborando os dados obtidos tanto nas análises de solo quanto de parâmetros de produtividade e qualidade da uva. A análise dos dados revelou uma relação as UGDs e a variabilidade encontrada nos vinhedos Merlot e Chardonnay.

CONCLUSÃO

O índice de vegetação por diferença normalizada é um parâmetro promissor para definir o potencial produtivo na videira.

As práticas de manejo do produtor provocaram a uniformização entre as UGDs impactando diretamente na produtividade e de qualidade dos vinhedos.

As análises de agrupamento e de PCA gera indicativos de que as UGDs podem ser agrupadas em duas UGDs e para o manejo adequado pode potencializar a diferença da produção e qualidade.

REFERÊNCIAS

BRAMLEY, R.G.V., OUZMAN, J., BOSS, P.K. Variation in vine vigour, grape yield and vineyard soils and topography as indicators of variation in the chemical composition of grapes, wine and wine sensory attributes: Vineyard variation in wines, grapes and soils. **Australian Journal of Grape and Wine Research**, v. 17, p. 217-229, 2011. https://doi.org/10.1111/j.1755-0238.2011.00136.x

BRAMLEY, R.G.V., OUZMAN, J., STURMAN, A.P., GREALISH, G.J., RATCLIFF, C.E.M., TROUGHT, M.C.T. Underpinning Terroir with Data: Integrating Vineyard Performance Metrics with Soil and Climate Data to Better Understand Within-Region Variation in Marlborough, New Zealand. **Australian Journal of Grape and Wine Research**, 8811402, 2023. https://doi.org/10.1155/2023/8811402

DEVAUX, N., CRESTEY, T., LEROUX, C., TISSEYRE, B. Potential of Sentinel-2 satellite images to monitor vine fields grown at a territorial scale. **OENO One**, v. 1 p. 53-58, 2019. https://doi.org/10.20870/oeno-one.2019.53.1.2293

ECHEVERRÍA, G., FERRER, M., MIRÁS-AVALOS, J. Effects of soil type on vineyard performance and berry composition in the Río de la Plata Coast (Uruguay). **OENO One**, v. 51, p. 251-261, 2017. https://doi.org/10.20870/oeno-one.2017.51.2.1829

FERRER, M., ECHEVERRÍA, G., PEREYRA, G., GONZALEZ-NEVES, G., PAN, D., MIRÁS-AVALOS, J.M. Mapping vineyard vigor using airborne remote sensing: relations with yield, berry composition and sanitary status under humid climate conditions. **Precision Agriculture**, v.21, p. 178-197, 2020. https://doi.org/10.1007/s11119-019-09663-9

FERRO, M. V. et al. Assessment of vineyard vigour and yield spatio-temporal variability based on UAV high resolution multispectral images. **Biosystems Engineering**, [s. l.], v. 231, p. 36-56, 2023.

Disponível em: https://www.sciencedirect.com/science/article/pii/S1537511023001149. Acesso em: 23 set. 2023.

FERRO, M. V.; CATANIA, P. Technologies and Innovative Methods for Precision Viticulture: A Comprehensive Review. **Horticulturae**, [s. l.], v. 9, p. 399, 2023. Disponível em: https://www.mdpi.com/2311-7524/9/3/399. Acesso em: 5 nov. 2023.

GATTI, M., GARAVANI, A., SQUERI, C., DITI, I., DE MONTE, A., SCOTTI, C., PONI, S. Effects of intra-vineyard variability and soil heterogeneity on vine performance, dry matter and nutrient partitioning. **Precision Agriculture**, v.23, p. 150-177, 2022. https://doi.org/10.1007/s11119-021-09831-w

GATTI, M., GARAVANI, A., VERCESI, A., PONI, S. Ground-truthing of remotely sensed within-field variability in a cv. Barbera plot for improving vineyard management. **Australian Journal of Grape and Wine Research**, v. 23, p. 399-408, 2017. https://doi.org/10.1111/ajgw.12286

GIOVOS, R., TASSOPOULOS, D., KALIVAS, D., LOUGKOS, N., PRIOVOLOU, A. Remote Sensing Vegetation Indices in Viticulture: A Critical Review. **Agriculture**, v. 11, 457, 2021. https://doi.org/10.3390/agriculture11050457

JASSE, A., BERRY, A., ALEIXANDRE-TUDO, J.L., POBLETE-ECHEVERRÍA, C. Intrablock spatial and temporal variability of plant water status and its effect on grape and wine parameters. **Agricultural Water Managemen**t, v. 246, 106696, 2021. https://doi.org/10.1016/j.agwat.2020.106696

KASIMATI, A., PSIROUKIS, V., DARRA, N., KALOGRIAS, A., KALIVAS, D., TAYLOR, J.A., FOUNTAS, S. Investigation of the similarities between NDVI maps from different proximal and remote sensing platforms in explaining vineyard variability. **Precision Agriculture**, v. 24, p. 1220-1240, 2023. https://doi.org/10.1007/s11119-022-09984-2

MATESE, A., DI GENNARO, S.F., Beyond the traditional NDVI index as a key factor to mainstream the use of UAV in precision viticulture. **Nature**, v. 11, 2721, 2021. https://doi.org/10.1038/s41598-021-81652-

MIELE, A.; FLORES, C. A.; ALBA, J. M. F. Efeito da variabilidade espacial de solos do Vale dos Vinhedos na composição do vinho Merlot - Safra 2012. [s. l.], v. 6, p. 30-38, 2014. Disponível em: https://www.enologia.org.br/default/uploads/revista/revista-30.pdf?d3 12a75327476bda651d52efe6647e94.

OLDONI, H., COSTA, B.R.S., BOGNOLA, I.A., SOUZA, C.R. DE, BASSOI, L.H., 2020. Homogeneous zones of vegetation index for characterizing variability and site-specific management in vineyards. **Scientia agricol**a, v. 78, e20190243, 2020. https://doi.org/10.1590/1678-992X-2019-0243

PEREYRA, G., PELLEGRINO, A., FERRER, M., GAUDIN, R. How soil and climate variability within a vineyard can affect the heterogeneity of grapevine vigour and production. **OENO One**, v. 57, p. 297-313, 2023. https://doi.org/10.20870/oeno-one.2023.57.3.7498

PEREYRA, G., PELLEGRINO, A., GAUDIN, R., FERRER, M. Evaluation of site-specific management to optimise Vitis vinifera L. (cv. Tannat) production in a vineyard with high heterogeneity. **OENO One**, v. 56, p. 397-412, 2022. https://doi.org/10.20870/oenoone.2022.56.3.5485

SAMS, B., BRAMLEY, R.G.V., SANCHEZ, L., DOKOOZLIAN, N., FORD, C., PAGAY, V. Remote Sensing, Yield, Physical Characteristics, and Fruit Composition Variability in Cabernet Sauvignon Vineyards. **American Journal of Enolgy and Viticulture**, v. 73, p. 93- 105, 2022, https://doi.org/10.5344/ajev.2021.21038

SILVA COSTA, B.R., OLDONI, H., DA SILVA, T.M.M., FARINASSI, L.G., BOGNOLA, I.A., BASSOI, L.H. How similar is the zoning of different vegetation indices: Defining the optimal framework for monitoring grapevines' growth within vigorous vineyards. **Scientia Horticultura**e, v. 322, 112404, 2023. https://doi.org/10.1016/j.scienta.2023.112404

SOZZI, M., KAYAD, A., MARINELLO, F., TAYLOR, J., TISSEYRE, B. Comparing vineyard imagery acquired from Sentinel-2 and Unmanned Aerial Vehicle (UAV) platform. **OENO One**, v. 54, p. 189-197, 2020. https://doi.org/10.20870/oeno-one.2020.54.1.2557

SQUERI, C., PONI, S., DI GENNARO, S.F., MATESE, A., GATTI, M., 2021. Comparison and Ground Truthing of Different Remote and Proximal Sensing Platforms to Characterize Variability in a Hedgerow-Trained Vineyard. **Remote Sensing**, v. 13, 2056, 2021. https://doi.org/10.3390/rs13112056

TARDAGUILA, J., STOLL, M., GUTIÉRREZ, S., PROFFITT, T., DIAGO, M.P. Smart applications and digital technologies in viticulture: A review. **Smart Agricultural Technology**, v. 1, 100005, 2021. https://doi.org/10.1016/j.atech.2021.100005

TONIETTO J., GUERRA C. C., MANDELLI F., SILVA G., MELLO L. M. R., ZANUS M. C., HOFF R. Monte Belo: Características da Identidade Regional para uma Indicação Geográfica de Vinhos. Bento Gonçalves-RS: Embrapa, Comunicado técnico 86, 2008.

ESPECTROSCOPIA DE INFRAVERMELHO PRÓXIMO PARA ESTIMATIVA DO TEOR DE NITROGÊNIO EM PLANTAS E GRÃOS DAS CULTURAS DE ARROZ, TRIGO, MILHO E SOJA

MÁRCIO GABRIEL MOTKE WRUBLESKI [1]; DIEGO LIMA LUCCHESI [2]; GABRIELA NAIBO [3]; TALES TIECHER [4]; ANDRÉ LUIS VIAN [5]

[1]Graduando. Faculdade de, Campus do Vale - Av. Bento Gonçalves, 7712 - Agronomia, Porto Alegre - RS, 91540-000. Universidade Federal do Rio Grande do Sul; [2]Mestrando. Faculdade de, Campus do Vale - Av. Bento Gonçalves, 7712 - Agronomia, Porto Alegre - RS, 91540-000. Universidade Federal do Rio Grande do Sul; [3]Doutorando. Faculdade de, Campus do Vale - Av. Bento Gonçalves, 7712 - Agronomia, Porto Alegre - RS, 91540-000. Universidade Federal do Rio Grande do Sul; [4]Docente. Faculdade de, Campus do Vale - Av. Bento Gonçalves, 7712 - Agronomia, Porto Alegre - RS, 91540-000. Universidade Federal do Rio Grande do Sul; [5]Docente. Faculdade de, Campus do Vale - Av. Bento Gonçalves, 7712 - Agronomia, Porto Alegre - RS, 91540-000. Universidade Federal do Rio Grande do Sul

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A espectroscopia de infravermelho próximo (NIRS) oferece um método de análise mais eficiente, com custos e geração de resíduos tóxicos menores. Embora geralmente utilizada para espécies individuais, este estudo buscou criar um modelo único capaz de prever a concentração de nitrogênio em plantas (arroz, trigo e milho) e grãos (arroz, trigo e soja) usando diversas técnicas de pré-processamento e métodos de calibração multivariada. Foram analisadas 471 amostras de grãos e 466 amostras de plantas, com análises químicas de referência feitas pelo método Kjeldahl e espectros coletados entre 780-2500 nm. Foram utilizados os pré-processamentos *Detrend (DET)*, *Standard Normal Variate (SNV)* e *Savitzky-Golay Derivative (SGD)*. Os modelos de predição foram desenvolvidos a partir dos seguintes métodos de calibração multivariada: *Partial Least Squares Regression* (PLSR) e *Support Vector Machine* (SVM). A calibração do modelo foi realizada através da validação cruzada *(Cross validation)* por meio de uma divisão aleatória em segmentos, resultando em previsões precisas da concentração de nitrogênio das amostras de ambos os grupos. Os resultados do estudo abrem novos horizontes ao demonstrar a viabilidade e as vantagens de um modelo amplo de predição para múltiplas culturas agrícolas.

PALAVRAS-CHAVE: Estimativa de nitrogênio; sensoriamento remoto; tecido vegetal

ABSTRACT

Near infrared reflectance spectroscopy (NIRS) offers a more efficient analysis method, with lower costs and less generation of toxic waste. While typically used for individual species, this study aimed to create a single model capable of predicting nitrogen concentration in both plants (rice, wheat, and corn) and grains (rice, wheat, and soybeans) using various preprocessing techniques and multivariate calibration methods. A total of 471 grain samples and 466 plant samples were analyzed, with reference chemical analyses performed using the Kjeldahl method and spectra collected between 780-2500 nm. Preprocessing techniques included Detrend (DET), Standard Normal Variate (SNV), and Savitzky-Golay Derivative (SGD). Prediction models were developed using multivariate calibration methods: Partial Least Squares Regression (PLSR) and Support Vector Machine (SVM). Model calibration was conducted via cross validation, resulting in accurate predictions of nitrogen concentration for both sample groups. The study's findings open new avenues by demonstrating the feasibility and advantages of a comprehensive prediction model for multiple agricultural crops.

KEYWORDS: ;

INTRODUÇÃO

O nitrogênio (N) é um nutriente indispensável para o crescimento das plantas por ser um constituinte de proteínas, ácidos nucleicos, clorofila e metabólitos especializados (Li et al., 2020). O adequado manejo nutricional de N nas culturas ao longo de todo o ciclo de produção é essencial para que as culturas obtenham elevadas produtividades de grãos, além do N estar diretamente relacionado com o conteúdo de proteína e na qualidade de grãos (Li et al., 2020; Mariotti et al., 2008; Kamboj et al., 2022).

O método mais usado para avaliar o teor de N em tecido vegetal é a análise química, através do método Kjeldahl (Tedesco et al., 1995). Porém, esse método possui desvantagens por ser uma técnica onerosa, demorada, exigindo a destruição das amostras e a utilização de reagentes químicos tóxicos que exigem tratamento de resíduos específicos (Liu *et al*., 2022). Por estas razões, as análises químicas tradicionais demandam muito custo para monitorar o status de N nas culturas (Miao et al., 2023).

A espectroscopia de infravermelho próximo - NIRs, surge como um método promissor e alternativo aos métodos analíticos tradicionais para a estimativa dos teores de nutrientes nos tecidos vegetais (Prananto et al., 2020). O NIRS é um tipo de espectroscopia vibracional de alta energia que é realizada na faixa de comprimento de onda de 750 a 2500 nm (Pasquini, 2018). Essa técnica baseia-se na absorção de radiação eletromagnética na região do infravermelho próximo, que corresponde às frequências de vibração das ligações C-H, O-H e N-H encontradas nos grupos funcionais de moléculas orgânicas (Pasquini, 2018).

Os desafios do método NIRS é que para a sua aplicação são necessárias à obtenção das características espectrais das amostras e da calibração de modelos multivariados para a estimativa dos teores de N. Murguzur et al. (2018), construíram um modelo calibrado para diversas espécies e obteram resultados satisfatórios para estimar o teor de N, apresentando a construção de modelos amplos. Portanto, a construção de modelos para estimar o teor de N para múltiplas espécies agrícolas possibilita uma maior usabilidade deste método na agricultura.

OBJETIVOS

Portanto os objetivos deste trabalho foi avaliar o uso da espectroscopia de infravermelho próximo (NIRS) para estimar o teor de N no tecido da parte aérea dessas culturas por meio da construção de modelos multivariados.

MATERIAL E MÉTODOS

As amostras de trigo, milho e soja foram obtidas de experimentos conduzidos na Estação Experimental Agronômica da Universidade Federal do Rio Grande do Sul (EEA/UFRGS) e as amostras de arroz foram obtidas na Estação Experimental Agronômica do Instituto Rio Grandense do Arroz (EEA/IRGA). A EEA/UFRGS localiza-se no município de Eldorado do Sul (RS) e a EEA/IRGA localiza-se no município de Cachoeirinha (RS). Ao todo foram coletadas 466 amostras de tecido vegetal da parte aérea de plantas de arroz (138), trigo (135) e milho (193) entre os estádios vegetativo e reprodutivo, e 471 amostras de grãos de arroz (73), trigo (93) e soja (305) no estádio de maturação fisiológica. As amostras utilizadas foram coletadas de experimentos onde buscou-se a variabilidade dos teores de nitrogênio (N) no tecido de planta. As amostras foram secas em estufa com circulação de ar a 65-70 °C e moídas na peneira em frações de até 2,5 mm. As cultivares das espécies que foram utilizadas no estudo: Soja (BRS 5601 RR; BASF 15b70); Trigo (BRS Parrudo; BRS Reponte; TBIO Toruk; TBIO Sossego; BRS Bela Jóia); Milho (B2418 VYHR; P3016 VYHR); Arroz (IRGA 424; IRGA 431).

Análises químicas e espectrais

As análises químicas para determinar as concentrações de N total das amostras foram realizadas no Laboratório de Fisiologia Vegetal do Departamento de Plantas de Lavoura da Faculdade de Agronomia (UFRGS), pelo método semi-micro de Kjeldahl (Tedesco et al. 1995). As análises espectroscópicas foram realizadas no Laboratório Federal de Defesa Agropecuária (LFDA - Ministério da Agricultura e Pecuária, MAPA), localizado em Porto Alegre (RS). Os espectros de infravermelho próximo (NIRS) foram coletados na faixa de 780-2500 nm, utilizando o espectrômetro MPA Bruker, com a função de refletância difusa com 60 leituras por espectro, com resolução espectral de 2 cm^{-1}. Para realização das leituras espectrais, foi utilizado placas de petry com 10 g de cada amostra. Após a aquisição dos dados espectrais das amostras, os espectros brutos (RAW) foram submetidos a três técnicas de pré-processamento espectral, sendo a *Detrend*, derivada de *Savitski-Golay* e a *Standard Normal Variate*. Todos os pré-processamentos foram realizados utilizando os pacotes *prospectrs* e *clusterSim* (Stevens & Ramirez-Lopez, 2020) no software R (R Core Team, 2023).

Calibração multivariada

Na calibração dos modelos foram utilizados dois métodos multivariados, sendo um modelo paramétrico (*Partial Least Squares Regression - PLSR)* e outro não paramétrico (*Support Vector Machine - SVM).* Foram utilizados os pacotes do software R *pls e 1071* do software R, respectivamente (Mevik et al., 2016; Meyer et al., 2019). Optou-se por utilizar os diferentes modelos devido à ocorrência de correlações lineares e não lineares entre o teor de N e as variáveis espectrais (Rossel & Behrens, 2010). A calibração dos modelos com PLSR e SVM foi realizada separadamente para os três pré-processamentos espectrais, sendo *Detrend* (DET), *Derivada de Savitski-Golay* (SGD), *Standard Normal Variate* (SNV) e os espectros brutos (RAW). Todos os modelos foram calibrados por validação cruzada usando uma divisão aleatória em 10-fold (Brus et al., 2011).

O desempenho dos modelos foi avaliado pelo coeficiente de determinação (R^2), relação entre o desempenho e a distância interquartil (RPIQ), erro médio quadrático de predição (RMSE) e Bias (Johnson et al., 2021; Miao *et al*., 2023; Murguzur et al., 2017; Santos et al., 2023). O nível de predição foi definido em relação com o R^2, sendo definido com predição alta $R^2 > 0,75$; nível de predição médio $0,50 \leq R^2 \leq 0,75$ e nível de predição não recomendado $R^2 < 0,50$. Considerou-se o nível de confiabilidade RPIQ Alto ≥ 3,0; Médio ≥ 1,9 e < 3,0, e Baixo ≥ 1,5 e < 1,9 (Johnson et al., 2019).

RESULTADOS E DISCUSSÃO

Na Figura 1 são apresentadas as médias das assinaturas espectrais (reflectâncias) das amostras de planta (arroz, trigo e milho) e grão (arroz, trigo e soja), com e sem pré-processamento. Verificou-se que diferentes espécies possuem comportamento espectral semelhante, pois cada espécie de planta tem um espectro de reflectância ou absorção único nas faixas do NIR (Prananto et al., 2020). Observamos uma tendência geral para as plantas, que é resultado de um padrão complexo de dispersão e absorção causados por componentes bioquímicos e estruturais presentes no tecido vegetal (Richardson et al., 2004). Os espectros de reflectância no NIR são afetados por sobretons moleculares e combinações vibracionais relacionadas ao alongamento e dobramento das ligações moleculares como O-H, N-H e C-H encontradas em grupos funcionais de moléculas orgânicas como água, carboidratos, lipídeos e proteínas (Das et al., 2020). Sendo os comprimentos de onda 1432nm, 1501nm, 1564nm, 2050nm e 2292nm relacionados diretamente com o conteúdo de N nas plantas (Turker-Kaya & Huck, 2017)

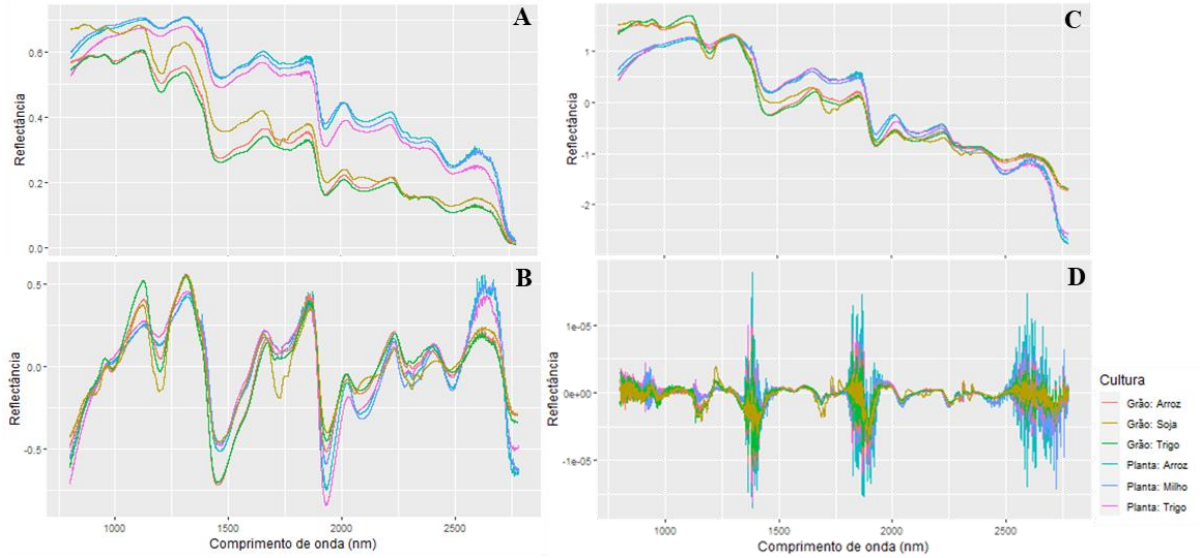


FIGURA 1. Assinatura espectral média das amostras de planta e grão sem pré-processamento (RAW) (A), pré-processada com Detrend (DET) (B), Standard Normal Variate (SNV) (C), Savitski-Golay Derivative (SGD) (D).

A utilização do pré-processamento com a técnica DET removeu a tendência sistemática presente nos espectros e destacou as bandas com maiores e menores reflectâncias, reduzindo o impacto de fatores não relacionados à composição química das plantas (Barnes et al., 1989). A técnica SGD usou a primeira derivada para calcular a taxa de variação da reflectância em relação aos comprimentos de onda, assim, observou-se que os espectros apresentaram feições realçadas e o sinal de linha de base das amostras foi removido (Rinnan et al., 2009). A técnica SNV suavizou cada espectro individualmente, subtraindo a média do espectro e dividindo pelo desvio padrão, padronizando os espectros em termos de distribuição normal, tornando-os mais comparáveis e realçando as variações espectrais relevantes (Barnes et al., 1989).

Na modelagem realizada para as plantas a diferença entre os scores foi menor, sendo que os comprimentos de onda 1482, 1820, 1920 e 2010 nm, obtiveram o score ~ 1,60. Esses comprimentos de onda estão relacionados com as ligações de O-H de carboidratos, O-H da celulose, C-H de carboidratos e O-H + C-O do amido respectivamente (Turker-Kaya & Huck, 2017; Aenugu et al., 2011).

A calibração multivariada foi realizada com os modelos estatísticos de Regressão de Partial Least Squares Regression (PLSR) e Suport Vector Machine (SVM) juntamente com as técnicas (SNV, DET e SGD). De acordo com o modelo de classificação sugerida por Johnson et al. (2019), todos os modelos apresentaram altos valores de R^2 (> 0,90), indicando que as variações nos teores de N podem ser estimadas pelos modelos.

As calibrações realizadas com os dados espectrais sem pré-processamentos (RAW) tiveram os menores valores de R^2, tanto para os modelos calibrados com as amostras de grão quando para planta. As calibrações realizadas com SVM foram superiores quando comparada com PLSR, sendo que o melhor modelo para ambos os grupos foi o SVM com o pré-processamento SNV onde foi obtido o R^2 de 0,99, RMSE de 0,10, RPIQ de 15,75 e Bias 0 para plantas e de R^2 de 0,99, RMSE de 0,16, RPIQ de 20,85 e Bias 0 para grãos. A Figura 2 apresenta o gráfico comparando com os valores mensurados pelo método químico e estimados pelo modelo (Figura 2).

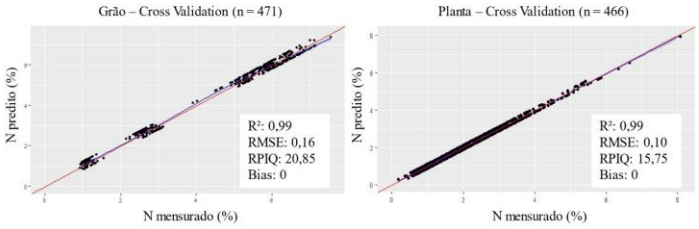


FIGURA 2. Gráfico de dispersão do conteúdo de N medido e estimado nos conjuntos compostos por amostras de grão (arroz, trigo e soja) e planta (arroz, trigo e milho).

Em um estudo conduzido por Johnson et al. (2021) foi calibrado modelos PLSR para a cultura do arroz com o pré-processamento SGD e se obteve R^2 acima de 0,81, RPIQ < 4,41 e RMSECV variando de 0,14 a 0,17. Já as calibrações realizadas com PLSR se obteve R^2 >0,94 quando combinadas com os pré-processamentos *Standard Normal Variate* (SNV) e *First Derivative* (FD), resultados esses que corroboram com o presente estudo, comprovando a precisão de NIRS para estimar N em plantas de arroz (Miao et al., 2023).

Tahmasbian et al. (2021), calibraram modelos PLSR para o trigo com R^2 = 0,96 e RMSE = 0,92 sem a utilização de pré-processamentos espectrais. Já modelos de aprendizado de máquina foram mais precisos para predição de N na cultura do trigo (R^2 = 0,96 e RMSE = 0,21), sendo o método SVM o mais estável em comparação ao PLSR (Yao et al., 2015). Pandey et al. (2017), calibraram modelos PLSR para a predição de N na planta de milho e obtiveram R^2 = 0,88 e RMSE = 0,47. Silva et al. (2023), obtiveram R^2 = 0,80, RMSE = 0,33, RPIQ = 1,92 e Bias = 0,0 utilizando o modelo PLSR. Ge et al. (2019), encontraram padrões semelhantes ao desenvolver modelos PLSR para o milho com R^2 = 0,87 e RMSE = 0,25.

O uso da espectroscopia NIR para estimativa de N em grãos se destaca aos modelos para predizer o teor de proteína. Kawamura et al. (2003), utilizaram o NIR para estimar o teor de proteína em grãos de arroz integral com precisão R^2 = 0,70, e para arroz beneficiado de R^2 = 0,76. A predição do teor de proteína em arroz integral foi de R^2 = 0,94 quando feita com o modelo Modified Partial Least Squares (MPLS) e pré-processamento Multiple Scatter Correction (MSC) (Xie et al., 2014).

CONCLUSÃO

A estimativa da concentração de nitrogênio em plantas (milho, arroz e trigo), e grãos (soja, trigo e arroz) foi mais precisa utilizando o modelo de calibração multivariado Support Vector Machine (SVM) combinado com o pré-processamento Standard Normal Variate (SNV). Adicionalmente, foi

verificado que é possível a calibração de um modelo único para estimar a concentração de nitrogênio em múltiplas culturas, não havendo necessidade de criar modelos específicos para cada espécie.

REFERÊNCIAS

AENUGU, H, P, R. et al Near infra red spectroscopy-An overview. **International Journal of ChemTech Research**, v. 3, n. 2, p. 825-836, 2011.

BARNES, R. J.; DHANOA, M. S.; LISTER, S. J. Standard normal variate transformation and de-trending of near-infrared diffuse reflectance spectra. **Applied spectroscopy**, v. 43, n. 5, p. 772-777, 1989. Available from: <https://doi.org/10.1366/0003702894202201>. Accessed: nov. 15, 2023. doi: 10.1366/0003702894202201.

BRUS, D. J.; KEMPEN, B.; HEUVELINK, G. B. M. Sampling for validation of digital soil maps. **European Journal of Soil Science**, v. 62, n. 3, p. 394-407, 2011. Available from: <https://doi.org/10.1111/j.1365-2389.2011.01364.x>. Accessed: dez. 11, 2023. doi: 10.1111/j.1365-2389.2011.01364.x.

CHADALAVADA, K. et al. NIR instruments and prediction methods for rapid access to grain protein content in multiple cereals. **Sensors**, v. 22, n. 10, p. 3710, 2022. Available from: <https://doi.org/10.3390/s22103710>. Acessed: mar. 10, 2023. doi: 10.3390/s22103710.

DAS, B. et al. Spectroscopy based novel spectral indices, PCA-and PLSR-coupled machine learning models for salinity stress phenotyping of rice. **Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy**, v. 229, p. 117983, 2020. Available from: <https://doi.org/10.1016/j.saa.2019.117983>. Accessed: dez. 15, 2023. doi: 10.1016/j.saa.2019.117983.

DOS SANTOS, G. L. A. A. et al. Spectral method for macro and micronutrient prediction in soybean leaves using interval partial least squares regression. **European Journal of Agronomy**, v. 143, p. 126717, 2023. Available from: < https://doi.org/10.1016/j.eja.2022.126717>. Accessed: dez. 15, 2023. doi: 10.1016/j.eja.2022.126717.

ECARNOT, M; COMPAN, F; ROUMET, P. Assessing leaf nitrogen content and leaf mass per unit area of wheat in the field throughout plant cycle with a portable spectrometer. **Field Crops Research**, v. 140, p. 44-50, 2013. Available from: <https://doi.org/10.1016/j.fcr.2012.10.013>. Accessed: dez. 15, 2023. doi: 10.1016/j.fcr.2012.10.013.

GE, Y. et al. High-throughput analysis of leaf physiological and chemical traits with VIS- NIR-SWIR spectroscopy: a case study with a maize diversity panel**. Plant Methods**, v. 15, n. 1, p. 1-12, 2019. Available from: https://doi.org/10.1186/s13007-019-0450-8>. Accessed: dez. 15, 2023. doi: 10.1186/s13007-019-0450-8.

HUAN, K. et al. Variable selection in near-infrared spectra: Application to quantitative non-destructive determination of protein content in wheat. **Infrared Physics & Technology**, v. 119, p. 103937, 2021. Available from: <https://doi.org/10.1016/j.infrared.2021.103937>. Accessed: dez. 15, 2023. doi: 10.1016/j.infrared.2021.103937.

JOHNSON, J.B. An overview of near-infrared spectroscopy (NIRS) for the detection of insect pests in stored grains. **Journal of Stored Products Research**, v. 86, p. 101558, 2020. Available from: <https://doi.org/10.1016/j.jspr.2019.101558>. Accessed: dez. 15, 2023. doi: 10.1016/j.jspr.2019.101558.

JOHNSON, J. M. et al. Application of infrared spectroscopy for estimation of concentrations of macro-and micronutrients in rice in sub-Saharan Africa. **Field Crops Research**, Amsterdam, v. 270, p. 108222, 2021. Available from: <https://doi.org/10.1016/j.fcr.2021.108222>. Accessed: dez. 15, 2023. doi: 10.1016/j.fcr.2021.108222.

KAMBOJ, U; GUHA, P; A, S. Comparison of PLSR, MLR, SVM regression methods for determination of crude protein and carbohydrate content in stored wheat using near Infrared spectroscopy**. Materials Today: Proceedings**, London, v. 48, p. 576-582, 2022. Available from: <https://doi.org/10.1016/j.matpr.2021.04.540>. Accessed: dez. 15, 2023. doi: 0.1016/j.matpr.2021.04.540.

KAWAMURA, S. et al. Development of an automatic rice-quality inspection system. **Computers and Electronics in Agriculture,** v. 40, p. 115-126, 2003. Available from: <https://doi.org/10.1016/S0168-1699(03)00015-2>. Accessed: dez. 15, 2023. doi: 10.1016/S0168-1699(03)00015-2.

KLECKA, W. R. **Discriminant analysis**. London: Sage, 1980

LIU, W. et al. Non-destructive measurements of toona sinensis chlorophyll and nitrogen content under drought stress using near infrared spectroscopy. **Frontiers in Plant Science**, v. 12, p. 809828, 2022. Available from: <https://doi.org/10.3389/fpls.2021.809828>. Accessed: dez. 15, 2023. doi: 10.3389/fpls.2021.809828.

MARIOTTI, F. et al. Converting nitrogen into protein-beyond 6.25 and Jones' factors. **Critical Reviews in Food Science and Nutrition**, v. 48, n. 2, p. 177-184, 2008. Available from: https://doi.org/10.1080/10408390701279749>. Accessed: dez. 15, 2023. doi: 10.1080/10408390701279749.

MARTENS, H; NAES, T. **Multivariate calibration**, John Wiley & Sons, New York, 1992.

MEVIK, B. H. et al. **Partial least squares and principal component regression**, Vienna, 2016.

MEYER, D. et al. e1071: misc functions of the department of statistics, probability theory group (formerly: E1071), TU Wien. **R package version**, Vienna, v. 1, n. 2, 2019.

MIAO, X.X. et al. Measurement of nitrogen content in rice plant using near infrared spectroscopy combined with different PLS algorithms. **Spectrochimical Acta Part a: Molecular and Biomolecular Spectroscopy**, v. 284, p. 121733, 2023. Available from: <https://doi.org/10.1016/j.saa.2022.121733>. Accessed: dez. 15, 2023. doi: 10.1016/j.saa.2022.121733.

MISHRA, P. et al. Identifying the best rice physical form for non-destructive prediction of protein content utilising near-infrared spectroscopy to support digital phenotyping. **Infrared Physics & Technology**, v. 116, p. 103757, 2021. Available from: <https://doi.org/10.1016/j.infrared.2021.103757>. Accessed: dez. 15, 2023. doi: 10.1016/j.infrared.2021.103757.

MISHRA, P; LOHUMI, S. Improved prediction of protein content in wheat kernels with a fusion of scatter correction methods in NIR data modelling. **Biosystems Engineering**, v. 203, p. 93-97, 2021. Available from: <https://doi.org/10.1016/j.biosystemseng.2021.01.003>. Accessed: dez. 15, 2023. doi: 10.1016/j.biosystemseng.2021.01.003.

ANCIN-MURGUZUR, F. J.; BARBERO-LÓPEZ, A.; KONTUNEN-SOPPELA, S.; HAAPALA, A. Automated image analysis tool to measure microbial growth on solid cultures. Computers and Electronics in Agriculture, 2018.

NAIBO, G. et al. Combining mid-infrared spectroscopy and machine learning to estimate nutrient content in plant tissues of yerba mate (Ilex paraguariensis A. St. Hil.). **Journal of Food Composition and Analysis**, p. 106008, 2024. Available from: <https://doi.org/10.1016/j.jfca.2024.106008>. Accessed: jan. 15, 2024. doi: 10.1016/j.jfca.2024.106008.

PANDEY, P. et al. High throughput in vivo analysis of plant leaf chemical properties using hyperspectral imaging. **Frontiers in Plant Science**, v. 8, p. 1348, 2017. Available from: https://doi.org/10.3389/fpls.2017.01348>. Acessed: dez. 15, 2023. doi: 10.3389/fpls.2017.01348.

PASQUINI, C. Near infrared spectroscopy: A mature analytical technique with new perspectives-A review. **Analytica Chimica Acta**, v. 1026, p. 8-36, 2018. Available from: <https://doi.org/10.1016/j.aca.2018.04.004>. Accessed: dez. 15, 2023. doi: 10.1016/j.aca.2018.04.004.

PRANANTO, J. A. et al. Near infrared (NIR) spectroscopy as a rapid and cost-effective method for nutrient analysis of plant leaf tissues. **Advances in Agronomy**, v. 164, p. 1-49, 2020. Available from: <https://doi.org/10.1016/bs.agron.2020.06.001>. Acessed: dez. 15, 2023. doi: 10.1016/bs.agron.2020.06.001.

R CORE TEAM. **R: a language and environment for statistical computing**. Vienna: R Foundation for Statistical Computing, 2023. Available from: < https://www.r-project.org/>.

RICHARDSON, D. et al. Multivariate analyses of visible/near infrared (VIS/NIR) absorbance spectra reveal underlying spectral differences among dried, ground conifer needle samples from different growth environments. **New Phytologist**, v. 161, n. 1, p. 291-301, 2004. Available from: <https://doi.org/10.1046/j.1469-8137.2003.00913.x>. Accessed: dez. 15, 2023. doi: 10.1046/j.1469-8137.2003.00913.x.

SHI, D. et al. Estimation of crude protein and amino acid contents in whole, ground and defatted ground soybeans by different types of near-infrared (NIR) reflectance spectroscopy. **Journal of Food Composition and Analysis**, v. 111, p. 104601, 2022. Available from: <https://doi.org/10.1016/j.jfca.2022.104601>. Accessed: dez. 15, 2023. doi: 10.1016/j.jfca.2022.104601.

SILVA, F. H. C. A. et al. Comparison of UV, visible and near-infrared, and mid-infrared spectrometers to estimate maize and sorghum leaf nutrients using dry-intact and ground leaves. **Computers and Electronics in Agriculture**, v. 211, p. 108001, 2023. Available from: <https://doi.org/10.1016/j.compag.2023.108001>. Accessed: dez. 15, 2023. doi: 10.1016/j.compag.2023.108001.

STEVENS, A.; RAMIREZ-LOPEZ, L. **An introduction to the prospectr package**. [S.l.: s.n.], 2020. Available from: <https://cran.rproject.org/web/packages/prospectr /index.html>. Accessed: dez. 15, 2023.

TAHMASBIAN, I. et al. Comparison of hyperspectral imaging and near-infrared spectroscopy to determine nitrogen and carbon concentrations in wheat. **Remote Sensing**, v. 13, n. 6, p. 1128, 2021. Available from: <https://doi.org/10.3390/rs13061128>. Accessed: dez. 15, 2023. doi: 10.3390/rs13061128.

TEDESCO, M. J. et al. **Análises de solo, plantas e outros materiais**. Porto Alegre: UFRGS, 1995.

TURKER-KAYA, S; HUCK, C. W. A review of mid-infrared and near infrared imaging: principles, concepts and applications in plant tissue analysis. **Molecules**, v. 22, n. 1, p. 168, 2017. Available from: <https://doi.org/10.3390/molecules22010168>. Accessed: dez. 15, 2023. doi: 10.3390/molecules22010168.

XIE, L.H. et al. Optimisation of near-infrared reflectance model in measuring protein and amylose content of rice flour. **Food Chemistry**, 142, p.92-100, 2014. Available from: <https://doi.org/10.1016/j.foodchem.2013.07.030>. Accessed: dez. 15, 2023. doi: 10.1016/j.foodchem.2013.07.030.

INCLUSÃO DE ÍNDICES DE VEGETAÇÃO SAR NA PREDIÇÃO DE PRODUTIVIDADE DA SOJA

ISABELLA ALVES DA CUNHA [1]; DERLEI DIAS MELO [1]; GUSTAVO MACEDO DE MELO BAPTISTA [3]; LUCAS RIOS DO AMARAL [2]

[1]Bolsista/Mestrado. Av. Cândido Rondon, 501 - Cidade Universitária, Campinas - SP, 13083-875. Universidade Estadual de Campinas ; [2]Docente. Av. Cândido Rondon, 501 - Cidade Universitária, Campinas - SP, 13083-875. Universidade Estadual de Campinas ; [3]Docente. Campus Universitário Darcy Ribeiro, Brasília-DF . Universidade de Brasília

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

O sensoriamento remoto por radar (SAR) tem sido explorado em aplicações agrícolas, fornecendo informações distintas dos sensores ópticos para complementar os dados e informações sobre as culturas. Neste estudo, investigamos o potencial de quatro índices de vegetação SAR para prever a produtividade da soja. Combinamos estes com outros quatro índices de vegetação ópticos, a fim de determinar se os índices de vegetação SAR podem aprimorar as previsões em conjunto com os índices ópticos. Observamos que a inclusão dos índices SAR resultou em melhorias mínimas nas previsões, o que não justifica seu uso devido aos custos operacionais associados ao seu processamento

PALAVRAS-CHAVE: Sensoriamento Remoto por Radar; Aprendizado de Máquina; Índices de Vegetação

ABSTRACT

Remote sensing by radar (SAR) has been explored in agricultural applications, providing distinct information from optical sensors to complement data and insights about crops. In this study, we investigated the potential of four radar-based vegetation indices to predict soybean yield. We combined these with another four optical vegetation indices to determine whether SAR vegetation indices can enhance predictions alongside optical indices. We observed that the inclusion of SAR indices resulted in minimal improvements in predictions, which does not justify their usage due to the operational costs associated with their processing.

KEYWORDS: ;

INTRODUÇÃO

Sistemas de sensoriamento por Radar de Abertura Sintética (SAR - *Synthetic Aperture Radar*) estão sendo cada vez mais explorados para uso em áreas agrícolas devido à sua capacidade de fornecer informações sobre a superfície, independentemente da cobertura de nuvens e da luz solar (Mulder et al., 2011). As imagens SAR possuem características distintas, como a capacidade de penetrar em objetos e a sensibilidade às propriedades da superfície, além da capacidade de controlar a polarização da radiação eletromagnética (Schmugge, 1983; Esa, 2023).

No que diz respeito à predição de produtividade em culturas, é importante reconhecer que os métodos tradicionais, utilizando sensoriamento óptico, têm alcançado desempenhos moderados, com coeficientes de determinação (R^2) variando aproximadamente de 0,7 a 0,8 (Amankulova et al., 2023). No entanto, a incorporação de dados do radar como alternativa viável oferece uma nova perspectiva. Ao contrário dos sensores ópticos, o radar tem a capacidade de capturar características da estrutura do dossel das culturas, como os coeficientes de retroespalhamento, que estão fortemente relacionados ao volume e às características do alvo, apresentando alta sensibilidade à água (Nasirzadehdizaji et al.,

2021). Esses dados complementam as informações obtidas pelos sensores ópticos, que geralmente estão restritos à refletância na superfície do dossel. Além disso, assim como no sensoriamento remoto óptico, o sensoriamento remoto por radar também possibilita a geração de índices de vegetação SAR, que se relacionam com o dossel das plantas, resultando em comportamentos distintos nas imagens e na obtenção de informações das culturas, aplicáveis também às imagens SAR (Zhang et al., 2015). Essa abordagem oferece uma oportunidade para aprimorar as previsões de produtividade, explorando as vantagens do sensoriamento por radar para fornecer informações complementares aos sensores ópticos.

Assim, estudos recentes, como os realizados por Hosseini et al. (2022) e Alebele et al. (2021), têm destacado o potencial das imagens SAR para melhorar as previsões de culturas com o apoio da aprendizagem de máquina. No entanto, esses autores não testaram a inclusão de índices de vegetação SAR para a predição, apenas utilizaram a informação da polarização, o que pode influenciar os resultados. Portanto, o objetivo deste estudo foi investigar se a inclusão de índices de vegetação por radar pode aprimorar a precisão da predição da produtividade da soja em conjunto com índices de vegetação ópticos, contribuindo assim como mais uma variável auxiliar nas predições de produtividade das culturas realizadas na agricultura de precisão.

OBJETIVOS

O objetivo deste estudo foi investigar se a inclusão de índices de vegetação por radar pode aprimorar a precisão da predição da produtividade da soja em conjunto com índices de vegetação ópticos.

MATERIAL E MÉTODOS

O estudo foi realizado em uma área de produção comercial de soja com aproximadamente 106 hectares, localizada no município de Cosmópolis, no interior do Estado de São Paulo. Durante o pico vegetativo do ciclo fenológico da cultura, coletamos dados SAR do Sentinel-1 e calculamos quatro índices de vegetação, a partir dos coeficientes de retroespalhamento da polarização VV e VH. As predições foram conduzidas com imagens do pico vegetativo determinado com base no Índice de Vegetação Melhorado (EVI - *Enhanced Vegetation Index*), empregando o algoritmo *Random Forest*. Quatro índices de vegetação SAR foram utilizados de forma individual, juntamente com os quatro índices de vegetação provenientes do Sentinel-2, os quais pertencem a diferentes grupos. Essa combinação foi realizada com o objetivo de explorar as diferentes informações fornecidas pelos sensores SAR e ópticos. Ao incorporar esses índices de diferentes fontes, esperamos capturar uma variedade mais ampla de características do dossel da cultura, o que pode resultar em previsões mais confiáveis. Para fins de comparação, também realizamos uma predição utilizando apenas os quatro índices de vegetação ótico.

Os dados da área experimental consistem na produtividade de grãos secos de soja (t/ha) de duas safras (2020/2021, 2021/2022), obtido por meio de monitor de produtividade instalado em colhedora. Esses dados podem apresentar *outliers* devido a diferentes fatores, como o manejo da largura de plataforma, manobras realizadas pela colhedora, falhas nos sensores, entre outros (Menegatti e Molin, 2004). Portanto, realizamos uma limpeza dos dados para reduzir erros e inconsistências. Para isso, adotamos o procedimento sugerido por Maldaner et al. (2021), com o objetivo de garantir a qualidade dos dados. Além disso, foi feito um buffer de 15m dos carreadores, visando reduzir a influência da refletância da bordadura. Dos dados remanescentes, selecionamos aleatoriamente 10 mil pontos para dar continuidade aos procedimentos, visando otimizar as análises e o processamento dos dados.

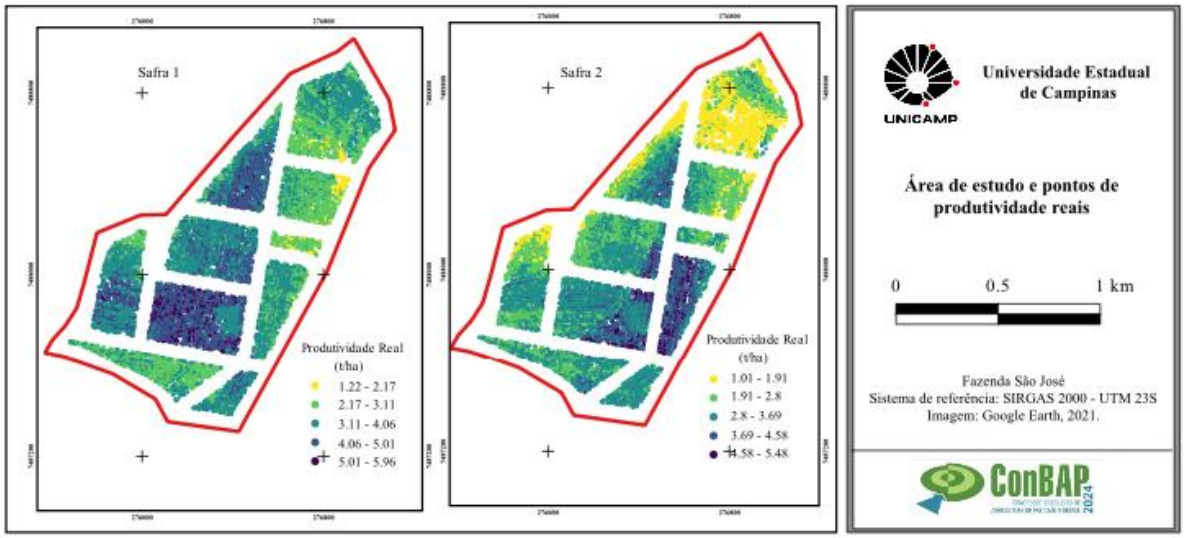


FIGURA 1. Mapa da área de estudo com os 10 mil os pontos de produtividade selecionados.

Dados SAR

Durante o pico vegetativo da cultura, coletamos informações do sensor SAR da missão Sentinel-1. O pico vegetativo foi determinado utilizando uma série temporal baseada no EVI, com dados do Sentinel-2, já que o pico vegetativo coincide com o valor máximo deste índice (Richetti et al. 2018) (Figura 2). O sensor SAR opera na banda C, disponibilizados gratuitamente pela Agência Espacial Europeia (ESA - *European Space Agency*). Adquirimos as imagens SAR no nível 1 SLC (*Single Look Complex*) no modo IW (*Interferometric Wide*), onde o sensor atua em dupla polarização: VH (emissão de ondas polarizadas na vertical e recebimento na horizontal) e VV (emissão e recebimento de ondas polarizadas na vertical) (aqui poderia citar a referência sobre essas polarizações).

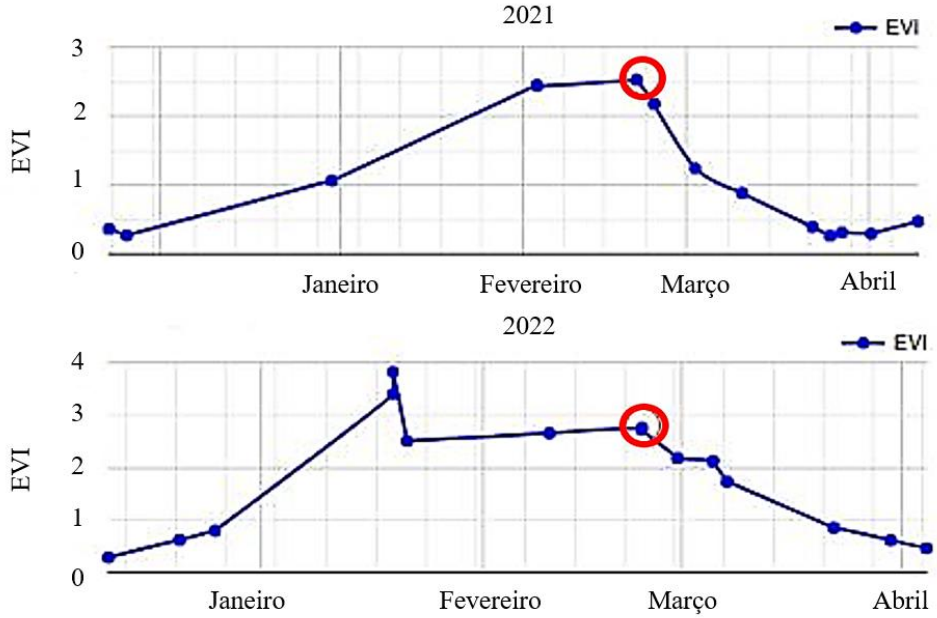


FIGURA 2. Série temporal de valores de EVI durante as duas safras, 2020/2021 e 2021/2022, destacando a imagem em que a imagem de pico vegetativo foi coletada (círculo vermelho).

Inicialmente, realizamos o processamento das imagens SAR (Figura 3) para extrair os coeficientes de retroespalhamento. Com base nesses dados, calculamos quatro índices de vegetação SAR (Tabela

1): DPSVIm, RVIm, RFDI e Pol. O Índice de Vegetação por Radar (RVIm - *Radar Vegetation Index*) emprega a intensidade resultante dos coeficientes de retroespalhamento e pode ser utilizado para indicar a condição e o estágio fenológico da cultura agrícola, além de capturar variações na tendência temporal (Haldar et al., 2018). O Índice de Degradação Florestal de Radar (RFDI - *Radar Forest Degradation Index*) auxilia na diferenciação de tipos de vegetação (Mitchard et al., 2012). Além disso, foi empregado o DPSVI (*Dual Polarization SAR Vegetation Index*), que utiliza as intensidades para estimar a biomassa vegetal, sendo proposto para duas polarizações (Periasimy, 2018). Também foi considerado o índice de polarização normalizada (Pol), o qual é sensível à rugosidade da superfície, à estrutura da vegetação e à biomassa seca, sendo útil na discriminação entre superfícies nuas e florestadas (Hird et al., 2017). Após gerarmos todas as imagens SAR, recortamos as imagens com uma distância de 15m dos carreadores para evitar influências que não sejam a cultura. Além disso, padronizamos os índices em uma escala de 0 a 1 para a comparação entre variáveis.

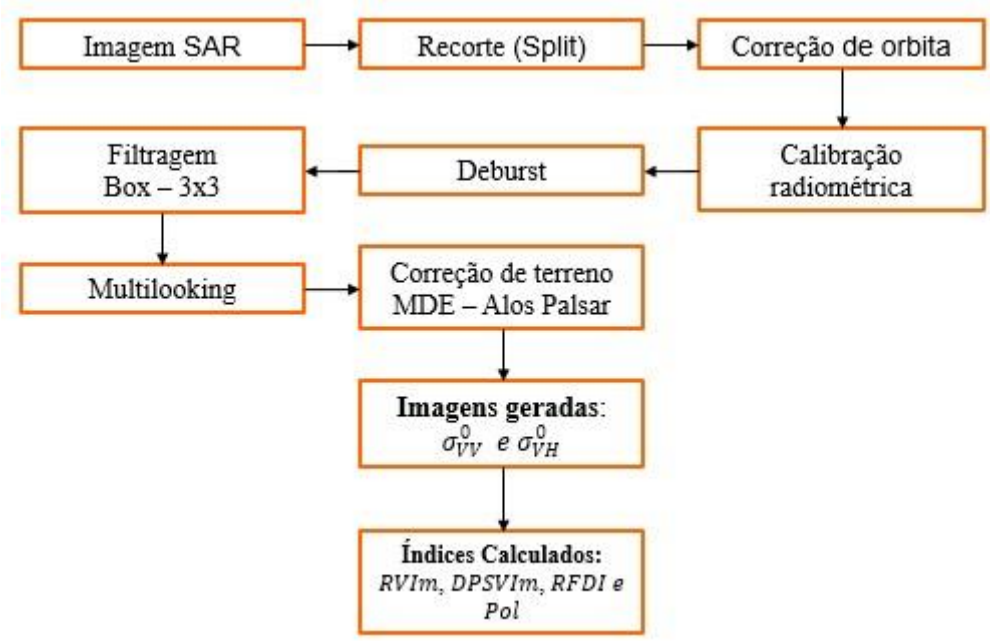


FIGURA 3. Fluxo de processamento das imagens SAR.

TABELA 1. Índices SAR calculados.

Índice SAR	Equação	Referência
DPSVIm	DPSVIm= (?VV?^2+VV*VH)/?2	Santos et al. (2021)
Pol	Pol= (VH-VV)/(VH+VV)	Hird et al, 2017
RFDI	RFDI= (VV-VH)/(VV+VH)	Hird et al, 2017
RVIm	RVI= (4*σ_VV^0)/(σ_VV^0+σ_VH^0)	Trudel et al. (2012)

Dados Óticos

Adquirimos imagens do Sentinel-2 com correção atmosférica de nível 2A no pico vegetativo. Calculamos quatro índices de vegetação (Tabela 2), cada um pertencente a grupos distintos de obtenção. O EVI é baseado em características de inclinação do espectro entre os picos de absorção e reflectância em vegetação sinteticamente ativa, o SFDVI é baseado em características de profundidade de feição espectral, o PVI é derivado da linha espectral do solo e o TCG pertence ao

grupo de Eixos Ortogonais, o qual atribui constantes para cada banda espectral que melhor representam o "verdor" (*greenness*) da vegetação. Assim, garantimos que todos os grupos de índices sejam usados, buscando ter a maior quantidade de informação possível sobre o dossel das culturas[1].

TABELA 2. Índices de Vegetação óticos calculados.

	Índice de Vegetação	Grupo	Equação
EVI	*Enhanced vegetation index*	Inclinação	2.5(NIR ? R) / (NIR + 6R ? 7.5B + 1)
SFDVI	*Spectral Feature Depth Vegetation Index*	Profundidade	[(NIR+G)/2] -[(R+RE)/2]
PVI[1]	*Perpendicular Vegetation Index*	Linha espectral do solo	(NIR-aR-b) / [(1+a^2)^0.5]
TCG	*Tasseled Cap Transformation Greenness*	Eixos Ortogonais	(0.6633NIR)+(0.0087SW1)+(- 0.2856SW2)

[1]a e b coeficientes da reta

[1] Artigo científico sobre este assunto foi submetido à revista *Precision Agriculture* e está em processo de correção pelos autores (*major revisions*). Amaral et al. Remote sensing imagery to predict soybean yield: a case study of vegetation indices contribution.

Analise dos dados

Extraímos os valores dos índices de vegetação ópticos e SAR às coordenadas dos 10 mil pontos de produtividade da soja. Em seguida, submetemos os dados à regressão por *Random Forest*, utilizando 70% dos dados para treinamento e 30% para teste. Os hiperparâmetros do modelo foram otimizados usando o método de otimização Bayesiana. Avaliamos cinco cenários diferentes: sendo 4 incluindo cada índice SAR e um apenas com os índices ópticos (Figura 4). Avaliamos o desempenho das predições com base no RMSE, R^2 e a importância das variáveis em cada cenário para determinar a contribuição das variáveis SAR na predição da produtividade da soja.

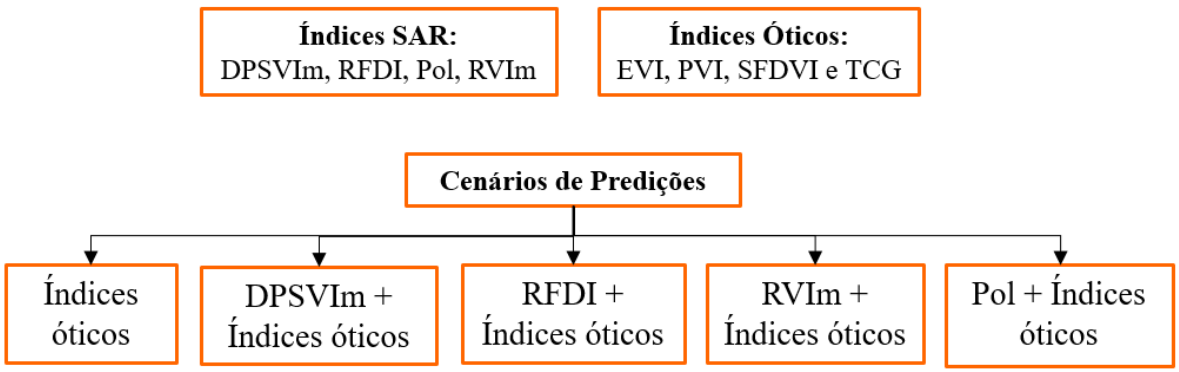


FIGURA 4. Cenários testados para predição.

RESULTADOS E DISCUSSÃO

A predição da produtividade da cultura de soja, ao incorporar uma variável SAR junto com mais quatro índices óticos, não contribuiu significativamente para a precisão dos modelos na estimativa de produtividade de soja na época do pico vegetativo. Ao comparar as predições utilizando apenas dados ópticos com aquelas que contem também a variável SAR, observamos uma mínima redução nos valores de RMSE, bem como um ligeiro aumento nos valores de R^2 (Figura 5). No entanto, essa melhoria foi pouca, mudando a partir da 3 casa decimal. Isso é corroborado pela similaridade entre

os mapas da produtividade predita das duas safras (Figura 6 e 7). Além disso, essa pequena melhoria foi conseguida mediante um considerável esforço computacional para o processamento das imagens, destacando a necessidade de um equilíbrio entre os benefícios obtidos e os recursos empregados na modelagem preditiva da produtividade da soja.

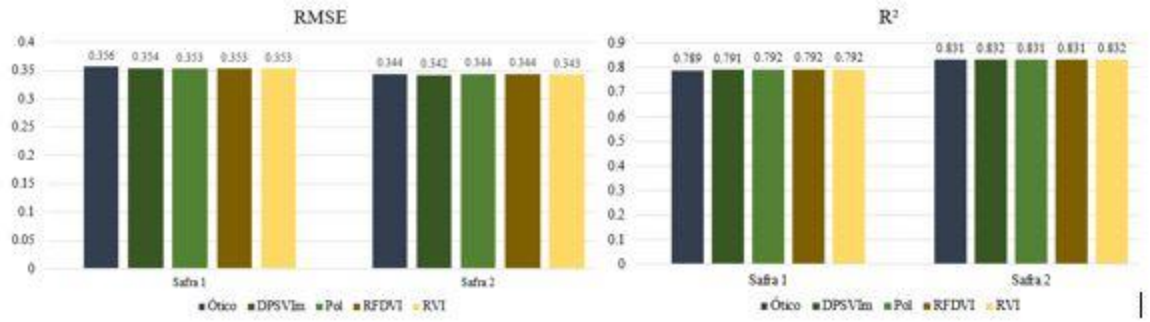


FIGURA 5. Desempenho das predições dos diferentes cenários de combinação de índices para as duas safras.

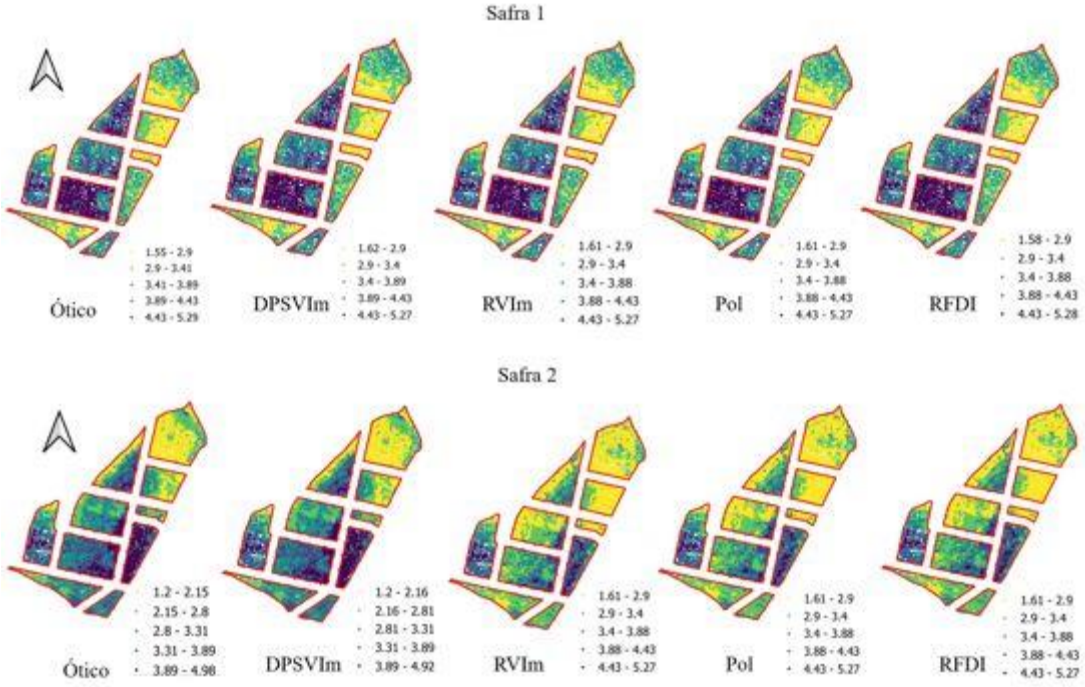


FIGURA 6. Pontos de produtividade preditos nas safras 1 e 2.

Na comparação entre os índices de vegetação SAR, a análise da correlação (tabela x) entre os índices SAR indica colinearidade entre eles, sugerindo que a inclusão de mais de um índice em cada cenário pode ser desnecessária. Da mesma forma, essa análise indica uma baixa correlação entre os índices SAR e os índices óticos, o que complementariam os resultados.

TABELA 3. Correlação entres os índices de vegetação

Produtividade	0,51	0,51	-0,02	0,11	-0,11	0,11	0,5	0,5
	EVI	0,94	0,13	0,092	-0,092	0,092	0,96	0,96
		PVI	0,14	0,071	-0,071	-0,071	0,99	0,99

	DPSVIm	-0,68	0,68	-0,68	0,16	0,13
		Pol	-1	1	0,063	0,084
			RFDI	-1	-0,063	-0,084
				RVI	-0,086	-0,062
					SFDVI	0,99
						TCG

Em termos de importância das variáveis para as predições, observamos resultados bastante semelhantes entre os índices SAR (Tabela 4). No entanto, o DPSVIm se destaca entre os índices de vegetação SAR devido à sua maior importância. Quando combinado com outros quatro índices óticos para prever a produtividade da soja, o SAR não se sobressai durante o pico vegetativo. Isso pode ser atribuído ao fato de que os índices óticos são mais numerosos nos cenários e eficazes em prever a produtividade nesse período (Richetti et al. 2018). Durante o pico vegetativo, a estrutura do dossel geralmente mostra uniformidade, porém, em estágios mais avançados ou tardios, essa estrutura pode se correlacionar de maneira mais significativa com a produtividade. Assim, a integração de dados óticos e SAR nesses estágios pode proporcionar um desempenho mais eficaz. Assim, para estudos futuros, recomendamos explorar a aplicação desses métodos em outras épocas durante a safra, além de explorar outras culturas agrícolas que apresentem uma relação mais clara entre os índices de vegetação e a produtividade.

TABELA 4. Importância dos índices nas predições por Random Forest

Índice de vegetação SAR	EVI	PVI	SAR	SFDVI	TCG
DPSVI	763,0	922,39	695,09	2201,93	3767,02
Pol	755,81	976,71	618,13	2188,47	3803,42
RFDI	778,47	997,30	628,78	2153,80	3774,28
RVI	760,20	983,31	630,15	2172,79	3779,94

CONCLUSÃO

Neste estudo, comparamos a predição da produtividade da soja com quatro índices de vegetação óticos de diferentes grupos e ao integrar um índice de vegetação SAR. Nossos resultados mostram que índices de vegetação SAR podem aprimorar a capacidade preditiva dos modelos de aprendizado de máquina na predição da produtividade da soja com índices de vegetação ótico. No entanto, observamos que essa melhora é mínima e pode não justificar o esforço computacional adicional, especialmente na época de pico vegetativo em que índices óticos tem maior relação com a produtividade.

AGRADECIMENTOS

Agradecemos o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, da FAPESP (processo n° 2022/03160-8) e à Fazenda São José pela disponibilização da área de estudo e dos dados de produtividade.

REFERÊNCIAS

ALEBELE, Yeshanbele et al. Estimation of crop yield from combined optical and SAR imagery using Gaussian kernel regression. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, v. 14, p. 10520-10534, 2021

AMANKULOVA, K., Farmonov, N., Akramova, P., Tursunov, I., & Mucsi, L. Comparison of PlanetScope, Sentinel-2, and landsat 8 data in soybean yield estimation within-field variability with random forest regression. Heliyon., 2023

EUROPEAN SPACE AGENCY (ESA). Sentinel-1 SAR technical guide. Disponível em: https://sentinels.copernicus.eu/web/sentinel/technical-guides/sentinel-1-sar. Acesso em: 18 jan. 2023.

HALDAR, Dipanwita; DAVE, Rucha; DAVE, Viral A. Evaluation of full-polarimetric parameters for vegetation monitoring in rabi (winter) season. The Egyptian Journal of Remote Sensing and Space Science, v. 21, p. S67-S73, 2018.

HIRD, J. N. et al. Google earth engine, open-access satellite data, and machine learning in support of large-area probabilistic wetland mapping. Remote Sensing, v. 9, n. 12, 1 dez. 2017.

HOSSEINI, Mehdi et al. Soybean Yield Forecast Using Dual-Polarimetric C-Band Synthetic Aperture Radar. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, v. 3, p. 405-410, 2022.

NASIRZADEHDIZAJI, R. et al. Sentinel-1 interferometric coherence and backscattering analysis for crop monitoring. **Computers and Electronics in Agriculture**, v. 185, p. 106-118, 2021.

MALDANER, L.F.; Canata, T.F.; Molin, J.P. An approach to sugarcane yield estimation using sensors in the harvester and zigbee technology. Sugar Tech 2022, 24, 813-821.

MENEGATTI, Leonardo AA; MOLIN, José P. Remoção de erros em mapas de produtividade via filtragem de dados brutos. Revista Brasileira de Engenharia Agrícola e Ambiental, v. 8, p. 126-134, 2004.

MESTRE-QUEREDA, A., Lopez-Sanchez, J. M., Vicente-Guijalba, F., Jacob, A. W., & Engdahl, M. E. Time-series of Sentinel-1 interferometric coherence and backscatter for crop-type mapping. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 13, 4070-4084. 2020

MITCHARD, E. T. A. et al. Mapping tropical forest biomass with radar and spaceborne LiDAR in Lopé National Park, Gabon: Overcoming problems of high biomass and persistent cloud. Biogeosciences, v. 9, n. 1, p. 179-191, 2012.

MULDER, V. L. et al. The use of remote sensing in soil and terrain mapping-A review. **Geoderma**, v. 162, n. 1-2, p. 1-19, 2011.

PERIASAMY, S. Significance of dual polarimetric synthetic aperture radar in biomass retrieval: an attempt on Sentinel-1. Remote Sens. Environ. 217, 537-549. 2018

RICHETTI, J., Judge, J., Boote, K. J., Johann, J. A., Uribe-Opazo, M. A., Becker, W. R., ... & Silva, L. C. D. A. Using phenology-based enhanced vegetation index and machine learning for soybean yield estimation in Paraná State, Brazil. Journal of Applied Remote Sensing, v. 12, n. 2, p. 026029-026029, 2018.

SCHMUGGE, T. J. Remote sensing of soil moisture: Recent advances. **Geoscience and Remote Sensing**, (3), 336-344, 1983.

ULABY, F.T.; Moore, R.K.; Fung, A.K. Microwave remote sensing - fundamentals and radiometry. Norwood, MA: Artech House, 1981a. v.1, 456 p. Cap. 1: Introduction, p. 1-60

ZHANG, H., LIN, H. Y. LI, "Impacts of Resource Normalization on Optical and SAR Data Fusion for Land Use/Land Cover Classification ", **Geoscience and Remote Sensing Letters**, vol. 12, pp. 1061-1065, 2015

GERAÇÃO DE NUVENS DE PONTOS MULTIESPECTRAIS POR FOTOGRAMETRIA À CURTA DISTÂNCIA

Beatriz Coêlho Silva [1]; Antonio Maria Garcia Tommaselli [2]
[1]Bolsista de Iniciação Científica. Presidente Prudente - São Paulo. Universidade Estadual Paulista 'Júlio de Mesquita Filho; [2]Docente, Depto. de Cartografia. Presidente Prudente - São Paulo. Universidade Estadual Paulista 'Júlio de Mesquita Filho

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
As câmaras multiespectrais são uma das tecnologias que estão em grande expansão na agricultura de precisão, permitindo a análise detalhada da vegetação e do solo. A coleta de imagens aéreas para a geração de mosaicos multiespectrais já é bastante comum, mas a possibilidade de uso de câmaras multiespectrais à curta distância é menos conhecida, permitindo a reconstrução das plantas em alto nível de detalhes e acurácia. Este trabalho tem por objetivo descrever um estudo de caso e analisar a qualidade geométrica de uma reconstrução tridimensional empregando um sensor de seis lentes e 14 bandas espectrais. A calibração das câmaras, orientação das imagens e geração das nuvens de pontos tridimensionais foi feita por técnicas fotogramétricas, permitindo acurácia sub-milimétrica e alto nível de resolução. O produto gerado permite extração futura de várias informações sobre as plantas, como altura, volume, área folear, doenças e deficiências, análises detalhadas da saúde das plantas e da produção agrícola.

PALAVRAS-CHAVE: Câmara multiespectral; Fotogrametria a curta distância; Nuvens de pontos

ABSTRACT
Multispectral cameras are among the technologies that are experiencing huge expansion in precision agriculture, allowing detailed analysis of vegetation, soil and other features. The acquistion of aerial images to generate multispectral mosaics is already quite common, but the option of using multispectral cameras at close range have been less approached, allowing the reconstruction of plants with a high level of details and accuracy. This work aims to assess a case study and analyse the geometric quality of a three-dimensional reconstruction using a sensor with six lenses and 14 spectral bands. Camera calibration, image orientation and generation of three-dimensional point clouds were carried out using photogrammetric techniques, allowing sub-millimetre accuracy and a high level of resolution. The generated product allows the future extraction of various information about plants, such as height, volume, leaf area, diseases and deficiencies. detailed analyses of plant health and agricultural production.

KEYWORDS: ;

INTRODUÇÃO

O uso de câmaras multiespectrais tem crescido na agricultura de precisão. Essas câmaras são capazes de captar imagens de múltiplas bandas espectrais e quando combinadas com técnicas de posicionamento geodésico, possibilitam uma aquisição de dados de forma dinâmica e sistemática para uma análise mais detalhada e precisa da vegetação e do solo (ESCOLÀ et al., 2017; VÁZQUEZ-ARELLANO et al., 2016).

A coleta de imagens de uma área de cultivo pode ser realizada de forma aérea ou terrestre, adequando-se as técnicas para o problema a ser solucionado. A partir das imagens coletadas pelas câmaras e

utilizando-se técnicas fotogramétricas, podem ser geradas nuvens de pontos tridimensionais, que são modelos numéricos detalhados que podem ter alta resolução espacial e espectral. Essa técnica envolve a análise das imagens e a determinação de correspondência entre pontos de referência presentes em diferentes fotos. Esses pontos são posteriormente utilizados para a fototriangulação, resultando na representação tridimensional da área na forma de modelos digitais de superfície e mosaicos das imagens. Caso sejam utilizadas câmaras multiespectrais, estes processos são aplicados para cada uma das bandas espectrais capturadas pela câmara.

As análises que podem ser realizadas com base nessas nuvens de pontos, são empregadas de diversas maneiras na agricultura de precisão. A partir dessas análises é possível extrair informações sobre a saúde das plantas, monitorar o seu crescimento, identificar áreas de estresse e até mesmo estimar a produção agrícola. Essas informações podem ser utilizadas para otimizar o uso de insumos aplicando-os de forma mais eficiente e precisa, ou também, para a identificação precoce de alterações e tomar medidas corretivas antes que os danos sejam significativos.

OBJETIVOS

O objetivo deste trabalho é descrever um estudo de caso e analisar a qualidade geométrica da reconstrução tridimensional utilizando um sensor de 14 bandas espectrais e 6 lentes, empregando técnicas fotogramétricas.

MATERIAL E MÉTODOS

A fotogrametria a curta distância viabiliza a reconstrução tridimensional precisa de objetos com imagens capturadas próximas ao sensor. Geralmente, o sensor é colocado em um tripé, ou em um sistema móvel, posicionado em estações de base curtas para maximizar a informação geométrica obtida. Apesar disso, gerar um modelo tridimensional da vegetação ainda apresenta desafios devido à sua complexidade, com folhas e galhos distribuídos em diferentes tamanhos e profundidades em relação ao sensor, o que pode confundir os algoritmos empregados para a determinação de correspondências entre pontos em diferentes imagens. Além disso, há significativas variações na iluminação, sombras e movimentações causadas por vento, o que interfere na realização de correspondências entre pontos.

2.1. Sensor multiespectral

O sensor utilizado foi desenvolvido pela empresa Agrowing (AGROWING, 2020), e é a combinação de uma câmara digital profissional com uma objetiva especial, composta por seis lentes e filtros, que permitem a coleta de imagens em 14 bandas espectrais. As especificações técnicas da câmara *Agrowing Sony Alpha 7R2 Sextuple Multispectral* (Figura 1) são apresentadas na Tabela 1.



Figura 1 - Sensor multiespectral: (a) Câmara Agrowing *Sextuple Multiespectral*; (b) disposição das bandas espectrais no quadro. Fonte: Agrowing.

Tabela 1 - Especificações da câmara. Fonte: Agrowing.

Campo de visão	45,90°
Distorção das lentes	<1%
Distância focal efetiva	21,6 mm
Abertura do diafragma	f/5.6 (fixo)
Peso do sensor, com bateria	845 g
Tamanho da imagem de quadro	9504 x 6336 pixels
Tamanho do píxel	0,0037 mm

2.2. Coleta de dados

Os dados fotogramétricos utilizados referem-se a uma planta de Citrus isolada, os quais foram adquiridos em 10 de julho de 2023 no campus de Presidente Prudente da UNESP. Para a realização desta coleta e processamentos posteriores, foi inserida uma placa de calibração com 36 pontos de apoio, cujas coordenadas foram definidas previamente para serem empregadas como referência no processamento fotogramétrico. Esta placa foi utilizada como forma de melhorar a qualidade geométrica na estimação dos parâmetros de orientação interior e exterior e, consequentemente, dos pontos reconstruídos.

Para este levantamento, foram utilizadas 21 estações de coleta, com uma distância de base de aproximadamente 0,5 m, contornando o objeto de interesse. Além disso, em cada estação, foram tomadas imagens em cinco alturas diferentes, com o intuito de obter uma cobertura completa do objeto.

A aquisição das imagens (Figura 2) foi feita com o sensor carregado pelo operador, com uma distância da câmara ao objeto de 2 m, no formato horizontal, utilizando fstop fixo de 5.6, ISO 100 e tempo de exposição variando entre 1/80 s e 1/125 s. A distância de focalização (distância imagem) foi determinada por uma análise prévia do borramento causado por desfoque por meio da PSF (Point Spread Function). Após a aquisição, foram extraídas as imagens geradas pelas seis lentes com o software proprietário da empresa Agrowing, gerando-se 14 imagens correspondentes às bandas espectrais, desde o azul até o infravermelho próximo.

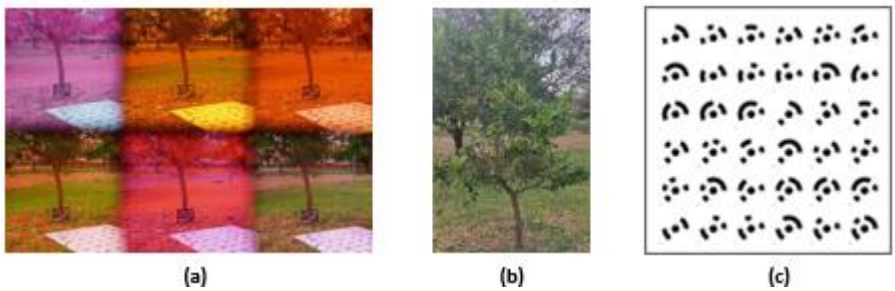


Figura 2 - Aquisição de dados: (a) Exemplo de imagem original da câmara de seis lentes; (b) detalhes da árvore e; (c) da placa de calibração.

2.3. Reconstrução tridimensional

O processo de geração da nuvem de pontos envolve as etapas de coleta dos dados, extração das bandas espectrais de cada imagem, calibração de cada lente, fototriangulação e geração da nuvem de pontos.

Neste trabalho foram enfatizadas as etapas de calibração e fototriangulação, que permitiram a estimação dos parâmetros de orientação interior do sensor e os parâmetros de orientação exterior de cada estação, a partir da identificação e medição de pontos de passagem e de pontos de apoio em cada imagem, sendo determinadas no mesmo processo as coordenadas tridimensionais dos pontos medidos nas imagens.

No processamento, a nuvem de pontos foi gerada por meio da correspondência por características comuns entre pontos em imagens sequenciais, utilizando técnicas fotogramétricas para a fototriangulação desse conjunto de imagens. Esse processamento foi realizado no *software* Metashape (AGISOFT, 2020), que dentre as ferramentas existentes, apresenta implementações eficientes na determinação automática de pontos correspondentes.

RESULTADOS E DISCUSSÃO

Foram geradas 14 nuvens de pontos tridimensionais, correspondentes às 14 bandas espectrais coletadas pelo sensor. O resultado visual para algumas bandas espectrais é mostrado na Figura 3, na qual é possível verificar que foram reconstruídos tanto o solo, quanto o pé de Citrus, além da placa que contém os pontos de apoio.

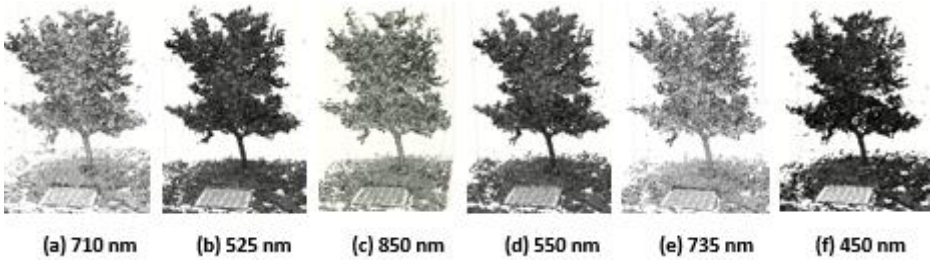


Figura 3 - Nuvem de pontos geradas para algumas das bandas espectrais.

Desses resultados, foi possível extrair dados quantitativos para análise de qualidade, sendo um deles o RMSE (*Root Mean Square Error* - Raiz do Erro Médio Quadrático) para cada componente da posição dos pontos de controle e de verificação determinados. Como a reconstrução é baseada nos pontos de controle, os valores com maior relevância para verificação da qualidade posicional foram aqueles encontrados para os pontos de verificação (Tabela 2), ou seja, pontos que não foram usados no processo de fototriangulação.

Tabela 2 - Raiz do Erro Quadrático Médio encontrada para os pontos de verificação de cada banda espectral.

Banda Espectral	X (mm)	Y (mm)	Z (mm)	Total (mm)
405nm	0,11	0,09	0,42	0,45
430nm	0,09	0,10	0,41	0,43
450nm	0,17	0,17	0,40	0,47
490nm	0,15	0,15	0,41	0,46
525nm	0,19	0,12	0,45	0,50
550nm	0,12	0,14	0,44	0,48
560nm	0,19	0,16	0,48	0,54
570nm	0,17	0,17	0,46	0,52
630nm	0,20	0,18	0,43	0,51
650nm	0,10	0,17	0,42	0,46
685nm	0,11	0,13	0,39	0,43
710nm	0,18	0,12	0,44	0,49
735nm	0,17	0,16	0,45	0,50
850nm	0,14	0,16	0,43	0,49
Média	0,15	0,15	0,43	0,48
Desvio-padrão	0,04	0,03	0,02	0,03

Conforme indicado pelos resultados apresentados na Tabela 2, a qualidade posicional alcançada é submilimétrica nas coordenadas X, Y e Z. Isso indica que a acurácia obtida pode ser comparada ou até mesmo superar a precisão alcançada por uma varredura a LASER, que atingem uma acurácia de 1 a 2 mm (KERSTEN; LINDSTAEDT, 2022) nos equipamentos mais precisos. Ademais, a reconstrução tridimensional realizada apresenta uma alta densidade de pontos, determinada por meio de correspondências nas imagens.

É importante destacar que foi gerada uma nuvem de pontos para cada uma das 14 bandas espectrais coletadas pelo sensor. O registro dessas bandas espectrais é aceitável, o que viabiliza a avaliação conjunta de mais de uma banda por vez. Essa característica permite a realização de diversas análises a partir das informações coletadas em um único levantamento.

CONCLUSÃO

O objetivo principal deste trabalho foi apresentar os resultados do uso de fotogrametria à curta distância para a geração de nuvens de pontos tridimensionais multiespectrais com alta acurácia, alta resolução espacial e espectral. A contribuição original foi a inserção de uma placa de calibração durante a aquisição que garante a obtenção de parâmetros com alta qualidade, resultando em uma nuvem de pontos com acurácia submilimétrica. Como sugestão para trabalhos futuros, pretende-se estudar a extração automática de informações geométricas e espectrais destas nuvens.

AGRADECIMENTOS

A Fapesp (processos 2022/12681-1 e 2021/06029-7) pelo fomento à pesquisa na forma de bolsa de Iniciação Científica e disponibilização de equipamentos.

REFERÊNCIAS

AGISOFT. **Metashape Agisoft**. Disponível em: <https://www.agisoft.com/>.

AGROWING. **Agrowing Sensors**. Disponível em: <https://agrowing.com/>.

ESCOLÀ, A. et al. Mobile terrestrial laser scanner applications in precision fruticulture/horticulture and tools to extract information from canopy point clouds. **Precision Agriculture**, v. 18, n. 1, p. 111-132, fev. 2017.

KERSTEN, T. P.; LINDSTAEDT, M. Geometric accuracy investigations of terrestrial laser scanner systems in the laboratory and in the field. **Applied Geomatics**, v. 14, n. 2, p. 421-434, jun. 2022.

VÁZQUEZ-ARELLANO, M. et al. 3-D Imaging Systems for Agricultural Applications-A Review. **Sensors**, v. 16, n. 5, p. 618, maio 2016.

DELIMITAÇÃO DE ZONAS DE AMOSTRAGEM DE SOLO E DETERMINAÇÃO DA QUANTIDADE NECESSÁRIA DE SUBAMOSTRAS PARA CARACTERIZAR ATRIBUTOS DE INTERESSE AGRONÔMICO

Derlei Dias Melo [1]; Isabella Alves da Cunha [1]; Thiago Luis Brasco [2]; Lucas Rios do Amaral [3]
[1]Mestrando em Engenharia Agrícola. Av. Cândido Rondon, 501 - Cidade Universitária, Campinas - SP, 13083-875. Faculdade de Engenharia Agrícola - FEAGRI Universidade Estadual de Campinas, Unicamp, Campinas - SP ; [2] Engenheiro Agrícola. Av. Cândido Rondon, 501 - Cidade Universitária, Campinas - SP, 13083-875. Faculdade de Engenharia Agrícola - FEAGRI Universidade Estadual de Campinas, Unicamp, Campinas - SP ; [3]Eng. Agrônomo, Professor Associado. Av. Cândido Rondon, 501 - Cidade Universitária, Campinas - SP, 13083-875. Faculdade de Engenharia Agrícola - FEAGRI Universidade Estadual de Campinas, Unicamp, Campinas - SP

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
A amostragem de solos para fins de mapeamento agrícola continua sendo um desafio para o manejo eficiente das lavouras, uma vez que os custos com amostragem limitam tal prática. Tradicionalmente, o mapeamento é realizado em formato de grade, sendo necessária elevada densidade amostral para criar mapas fidedignos. Entretanto, essa abordagem possui elevados custos amostrais, o que por vezes se torna um limitante. Em função disso, é apresentada uma abordagem para delimitar zonas de amostragem de solo onde há restrição no número de amostras, com base na classificação pedológica e suscetibilidade magnética do solo. Neste estudo, foram testadas amostragens em zonas para mapeamento do potássio (K), fósforo (P) e argila do solo em uma área produtora de grãos de 107 hectares. A abordagem por zonas permitiu mapear de forma eficiente os atributos quando comparados a uma amostragem em grade amostral esparsa (2,5 hectares por amostra) e a um valor médio para toda a área. Além disso, foi identificado que o número de pontos de coleta dentro de cada zona não deve ser inferior a 2 para compor uma amostra. Assim, a amostragem de solo com base em zonas é uma alternativa interessante para mapeamento dos atributos de interesse agronômico e prescrição de fertilizantes em doses variadas.

PALAVRAS-CHAVE: Zona de Manejo; Mapeamento digital do solo; Fertilidade do solo

ABSTRACT
Soil sampling for agricultural mapping purposes remains a challenge for efficient crop management, as sampling costs limit such practice. Traditionally, mapping is carried out in grid format, requiring high sample density to create reliable maps. However, this approach entails high sampling costs, which sometimes become a limiting factor. Consequently, we present an approach to delimit soil sampling zones where there are constraints on sample numbers, based on soil pedological classification and soil magnetic susceptibility. In this study, we tested zone sampling for mapping potassium (K), phosphorus (P), and soil clay in a grain-producing area of 107 hectares. The zone approach allowed for efficient mapping of attributes when compared to sparse grid sampling (2.5 hectares per sample) and a mean value for the entire area. Additionally, we identified that the number of collection points within each zone should not be less than 2 to compose a sample. Thus, zone-based soil sampling presents an interesting alternative for mapping agronomically relevant attributes and prescribing fertilizers at variable rates.

KEYWORDS: ;

INTRODUÇÃO

A proposta da Agricultura de Precisão (AP) é investigar e tratar as demandas da cultura de forma especializada, fornecendo a quantidade correta dos insumos no local em que é demandado (MOLIN et al., 2015). Nesse sentido, o planejamento amostral é um dos passos mais importantes na investigação da variabilidade espacial das propriedades do solo para fins de recomendação de fertilizantes em doses variadas, de forma que a tomada de decisão e seu resultado estão diretamente ligados à qualidade da amostragem. Assim, entender a variabilidade espacial do solo é um pré-requisito para uma agricultura mais eficiente (KOUNTIOS et al., 2018).

São diversas as formas de amostragem de solo (MOLIN et al., 2015). Cada forma de amostragem possui vantagens e desvantagens; todavia, a mais difundida para fins de AP é a grade regular. Para confecção da grade amostral, comumente os prestadores de serviços utilizam uma grade amostral com pontos espaçados regularmente, pois possui cobertura espacial homogênea (BRUS, 2019). Atributos como fósforo e potássio necessitam de amostragem em alta densidade para serem mapeados de forma eficiente (CHERUBIN et al., 2015; AMARAL E JUSTINA, 2019). Entretanto, os custos com amostragem e análise laboratorial podem ser um empecilho para confecção de uma grade amostral que atenda essas características. Em função disso, formas alternativas às grades têm sido buscadas para otimizar a amostragem, especialmente quando há um limitante financeiro que restringe o número amostral.

Uma das formas de amostragem que podem ser usadas em contrapartida às grades regulares são as amostragens por zonas de manejo. Nela, camadas de informação podem ser usadas para subdividir a área de estudo e inferir sobre sua homogeneidade (CÓRDOBA et al., 2016; OLDONI et al., 2019). Todavia, essa metodologia leva em conta a realização de todo um manejo na área, e não exclusivamente o zoneamento com finalidade de mapeamento do solo, sendo que, geralmente, resultam em áreas maiores, que possuem assim maior variabilidade dos atributos do solo ao longo de sua extensão. Assim, são demandadas adaptações nessa técnica para obter zonas homogêneas de solo que sejam eficientes em reduzir a variabilidade de atributos do solo que são importantes para a recomendação de fertilizantes e tomada de decisão.

OBJETIVOS

Diante disso, o objetivo deste trabalho foi investigar se uma abordagem utilizando classes de solo e um sensor de suscetibilidade magnética para criação das zonas de amostragem é capaz de reduzir as incertezas no mapeamento das propriedades do solo em comparação à uma grade esparsa de amostragem, a qual é frequentemente adotada na prática. Além disso, quando essa criação de zonas é efetuada, talvez a principal pergunta do usuário seja com relação ao número mínimo de subamostras necessárias para caracterizar adequadamente a zonas. Assim, este trabalho também teve o objetivo de elucidar essa questão.

MATERIAL E MÉTODOS

A área de estudo possui 107 hectares e está localizada no município de Cosmopólis, estado de São Paulo, Brasil, coordenadas 22°41'55,16"S e 47°10"34,15"W. O clima é classificado no sistema de Koppen como Cwb - subtropical úmido com inverno seco e verão quente e precipitação média anual e temperatura de 1300-1600 mm e 20-22 °C, respectivamente. O terreno é suavemente ondulado e o solo é predominante um Latossolo, com classe textural em superfície (0-20 cm) variando de argila a franco-argilo-arenosa. O cultivo de grãos é predominante na área, com plantio de soja na primeira safra, intercalando entre Aveia e Sorgo granífero na segunda safra.

Em toda a área de estudo, foi realizada uma amostragem densa de pontos de coleta de solo, com uma grade amostral regular de 40 por 40 metros, correspondendo a 6 pontos amostrais por hectare (Figura 1a). Cada ponto amostral corresponde a uma amostra composta oriunda de seis subamostras coletadas

em um raio de cinco metros do ponto central, utilizando um quadriciclo instrumentado com broca automatizada. As amostras foram coletadas na profundidade de 0 a 20 cm, pois essa é a profundidade recomendada para a recomendação de fertilizantes em áreas produtoras de grãos. Essa alta densidade amostral permitiu simular diversas configurações amostrais na área. As amostras compostas foram encaminhadas para um laboratório comercial de análise de solo para determinação dos teores dos elementos de interesse agronômico. Neste estudo, utilizamos apenas os dados de potássio (K), fósforo disponível (P) e teor de argila. O comportamento da distribuição dos valores desses atributos está na Tabela 1.

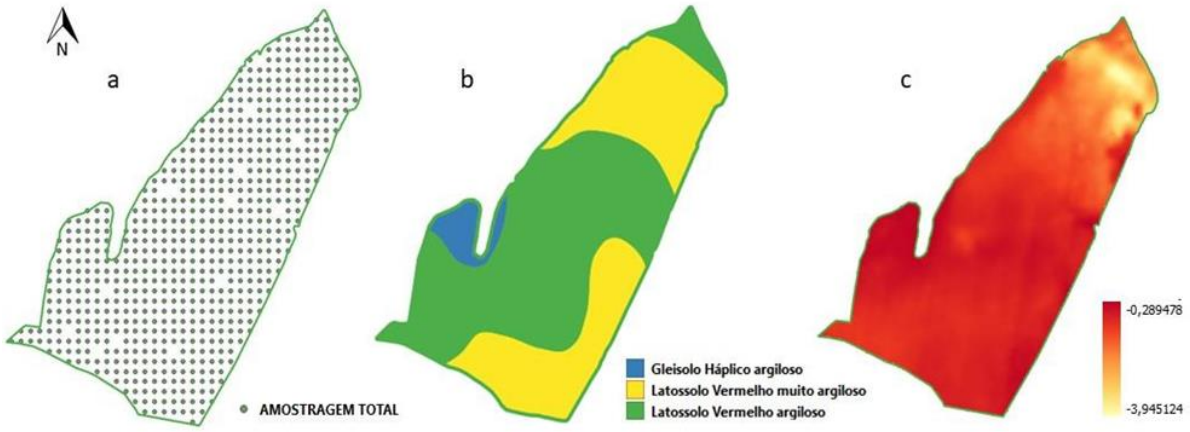


FIGURA 1. Pontos amostrais em grade densa (a), classes de solo (b) e mapa de susceptibilidade magnética (c).

TABELA 1. Resultado da estatística descritiva do Potássio (K), Fósforo (P) e Argila disponível para a todos os pontos amostrais na área de estudos.

Variaveis	Média	Mediana	Desv.Padrão	C. Variação	Mínimo	Máximo
K	6,0	5,3	3,0	50,5	0,8	19,3
P	50,5	45	23,5	46,5	13	164
Argila	460,5	459	108,6	23,5	108	750

A metodologia proposta visou inferir a variabilidade das áreas de estudo através da macro e micro variabilidade presente no solo. O intuito da divisão em macrorregiões é identificar zonas homogêneas em termos de tipos de solo e, posteriormente, subdividir essas zonas em microrregiões que representam a variabilidade na camada mais superficial do solo, para, assim, realizar a delimitação das zonas de amostragem de solo. As variáveis utilizadas para delimitar as macrozonas foram as classes taxonômicas de solo (Figura 1b), conforme a classificação da EMBRAPA SOLOS (2018). Essas macrozonas foram então subdivididas com base na variabilidade observada por um sensor de suscetibilidade magnética do solo (SM), que tem se mostrado um atributo eficiente na identificação de zonas específicas de manejo (Matos et al., 2023). Os dados foram obtidos a uma profundidade de 37,5 cm, utilizando um sensor EM38MK (Geonics, Canadá). O equipamento foi tracionado por um quadriciclo com passadas a cada 30 metros, sendo posteriormente confeccionado um raster contínuo por meio de krigagem ordinária (Figura 1c).

O número ideal de micro zonas dentro de cada classe de solo foi determinado em função da variabilidade da SM e do tamanho da área da classe (Eq. 1). O pressuposto básico é que se há maior variabilidade na SM, provavelmente haja maior variabilidade dos atributos do solo. A fórmula, adaptada de Wang et al. (2022), que determina o número de zonas de amostragem de solo, parte de

um número de amostras arbitrariamente definida, o que costuma ser o que ocorre na prática de campo, geralmente em função do investimento liberado para tal levantamento. No presente estudo, partimos do pressuposto que o investimento estava limitado a dez amostras para a área total, o que geraria zonas com área média de ~10 hectares, que está no intervalo recomendado para amostragens convencionais de solo na agricultura.

SNh = SN. Ah . CVh / ?1 Ah . CVh Eq. 1

SNh - Número de microzonas em cada classe de solo;

SN - Número de zonas a ser direcionado na área, definido arbitrariamente (n = 10);

Ah - Área de cada classe de solo em estudo (ha);

CVh - Coeficiente de variação da susceptibilidade magnética em cada classe de solo.

As zonas foram criadas pela metodologia de agrupamento fuzzy, conforme utilizada por Oldoni et al. (2019). Após a criação das zonas, foram simuladas seis diferentes densidades de amostragens compostas dentro dessas zonas, com número amostral variando de 1 a 5 pontos amostrais (Figura 2). Cada ponto amostral foi composto por 6 subamostras em um raio de cinco metros do ponto central, já que esse é o procedimento usual dos prestadores de serviço em agricultura de precisão, devido à logística ser mais simples do que o caminhamento em zigue-zague por toda a área. Também foi simulada uma amostragem média, com todos os pontos amostrais em cada zona, que foi tomada como a amostragem média verdadeira para a zona. O intuito dessas 6 amostragens por zona foi determinar o número ideal mínimo de amostras necessário para representar nossas zonas. Cada uma dessas densidades amostrais compôs uma única amostra composta, que representou a zona.

Buscando comparar o resultado deste zoneamento com o que é usualmente feito pelos prestadores de serviço e usuários de Agricultura de Precisão (AP), comparou-se o mapeamento executado por zonas com os resultados de uma grade amostral regular de 2,5 hectares por amostra (Figura 2).

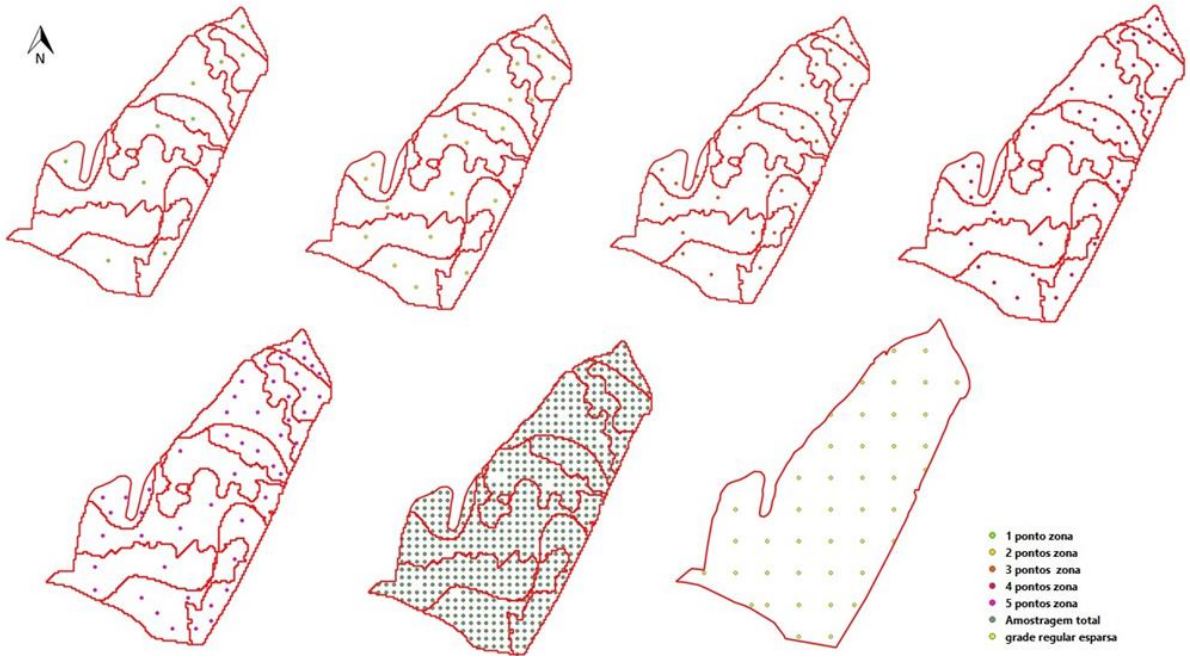


Figura 2. Zonas de Solo com Diferentes Níveis de Subamostragem dentro da Zona: Variação de 1 a 5 Pontos de Subamostragem e Pontos Totais para Composição da Amostragem Média, e com Grade Esparsa de 0,4 Pontos por hectare.

Após definir as zonas para cada atributo de interesse e gerar os mapas interpolados, utilizamos os pontos amostrais que não compuseram as grades como pontos de validação externa. O valor de cada ponto era previamente conhecido e, dessa forma, foi possível comparar os valores reais e preditos para cada metodologia de mapeamento: zonas com 1 a 5 subamostras e amostragem em grade esparsa, utilizando o erro médio absoluto (MAE). A título de comparação, também foi calculado o MAE caso a área fosse representada por um único valor médio, simulando uma amostragem convencional que resultaria em uma aplicação de fertilizantes em dose uniforme em toda a área. Essa abordagem é denominada aqui como amostragem convencional.

RESULTADOS E DISCUSSÃO

De acordo com o cálculo para delimitar o número de zonas, ficou estipulada 5 zonas de amostragem para o Latossolo Vermelho argiloso, 4 zonas para o Latossolo Vermelho muito argiloso e 1 zona para o Gleissolo Háplico argissolo. O tamanho das zonas variou de 2,84 hectares a 27,01 hectares (Figura 3).

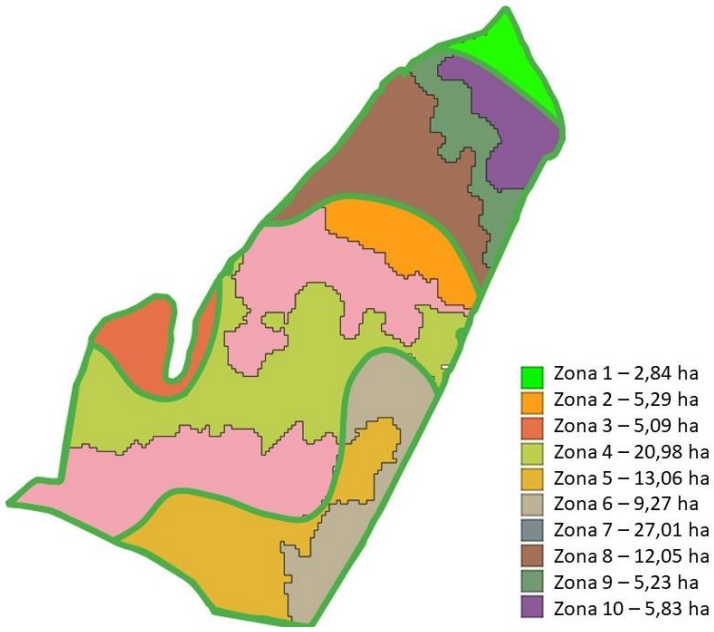


FIGURA 3. Zonas de amostragem de solo.

Ao comparar o erro médio absoluto (MAE) obtido para a amostragem de fósforo em três diferentes cenários - área total (Convencional), zonas de manejo e interpolação - observamos que o MAE para a amostragem na área total, independentemente do número de amostras, foi menor ou igual ao das outras duas situações (Figura 4c). A amostragem convencional normalmente é a que apresenta maior chance de erro, já que despreza a espacialidade das amostras. Todavia, ao se mostrar igual em termos de erro em relação às demais estratégias de amostragem estudadas, mostra que nenhum dos cenários (zonas, grade densa e esparsa) resultou em melhor representação do P ao longo da área. Desse modo, no caso do P, a melhor abordagem seria trabalhar com um único valor de P para a área toda, seguida por uma única recomendação de fertilizante fosfatado. Esse resultado se deve devido à aleatoriedade e baixa dependência espacial do P (Tabela 2), indicando que essa variável não está agrupada espacialmente e, portanto, tanto interpolação quando criação de zonas não seria indicado..

TABELA 2. Agrupamento espacial medido pelo índice de dependencia espacial (SDI), parâmetros dos variogramas (a: alcance - m, c0: efeito pepita, c1: contribuição) e da validação cruzada (r2 e RMSE entre predito e observado) para os valores de P, K e Argila disponíveis para o conjunto de dados denso original.

Atributo	*a*	c0	c1	r2	RMSE	SDI
P	400	436	132	0,104	22,32	23,3%
K	400	2,245	3,708	0,65	1,81	62,3%
Argila	770	0	14270	0,920	29,05	100%

Quanto aos métodos de amostragem para caracterizar o potássio, os resultados dos mapeamentos foram contrários aos do fósforo: a forma convencional (amostragem média) apresentou os maiores erros, seguida da grade regular esparsa e da amostragem por zonas (Figura 4b). Por possuir dependência espacial moderada (Tabela 2), a forma convencional se mostra inadequada, já que considera a área como valores médios fixos, o que já era esperado, pois é sabido que essa forma frequentemente apresenta maiores erros preditivos. A grade regular esparsa, por sua vez, apresentou erro amostral praticamente igual ou maior que a amostragem proposta por zonas. Por não possuir dependência espacial forte (Tabela 2), a krigagem ordinária não gera um mapa preditivo tão bom. As zonas, em contrapartida, tiveram resultados bons em termos práticos para o mapeamento desse atributo. Sendo assim, apesar dos erros do mapeamento serem relativamente parecidos, o número de amostras compostas utilizadas para gerar os mapas por zonas corresponde a cerca de 23% do total necessário para gerar a grade esparsa, o que gera uma economia relevante nos custos de amostragem e análise de solo.

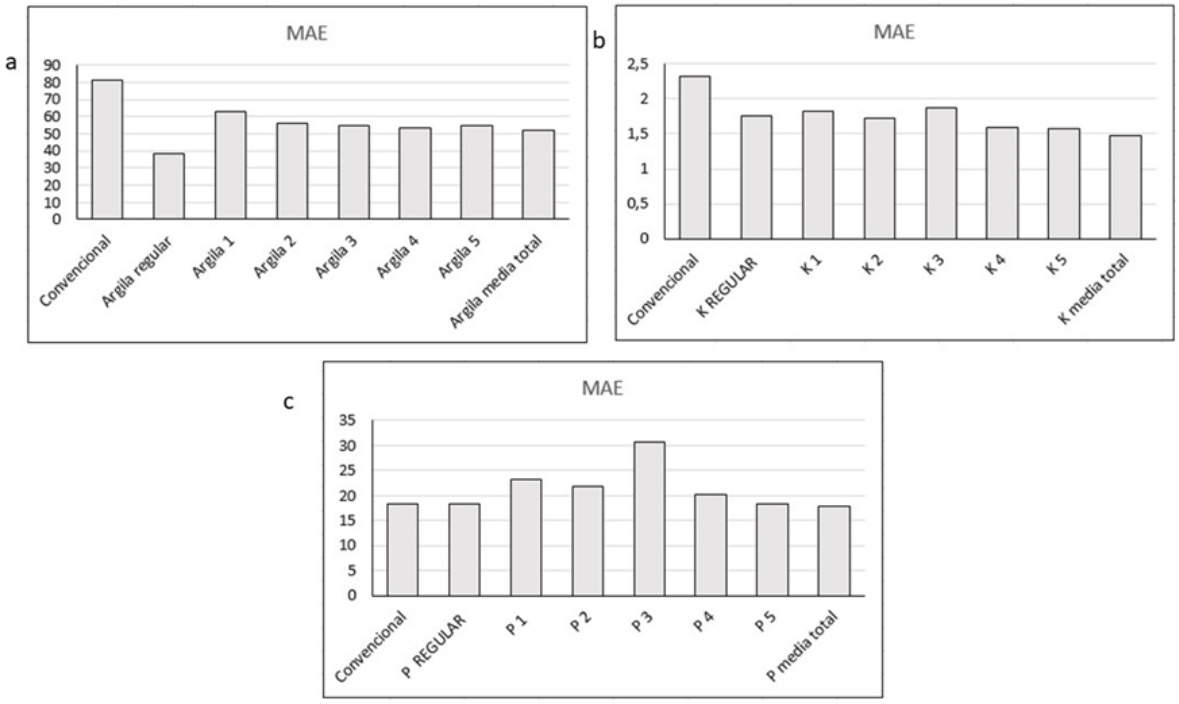


FIGURA 4. Erro médio absoluto das amostragens para teor de argila, Potassio (K) e Fósforo disponivel (P).

As zonas possuem similaridade em termos médios de K para os diferentes números de subamostragem (Figura 5). As zonas 1, 2, 3, 6, 9 e 10 tiveram áreas menores que 10 hectares, e em geral independente do número de subamostras, os valores médios foram muito parecidos. Em muitas zonas apenas um ponto de amostra composta foi suficiente para representar os valores de potássio em comparação com a média de todos os pontos amostrais. Entretanto, é arriscado sugerir a coleta de apenas um ponto, haja vista que pode haver contaminação da amostra, sendo sugerido a coleta superior a dois pontos para reduzir a probabilidade do erro amostral. Zonas inferiores a treze hectares

foram bem caracterizadas a partir de dois e três pontos amostrais, já as superiores a esse tamanho, tiveram melhor caracterização a partir de quatro pontos (Figura 5). Essa homogeneidade que as zonas apresentam, permitem que os amostradores otimizem o tempo amostral, não necessitando de número elevado de amostras, coletadas em zigue-zague, conforme vem sendo recomendada no decorrer dos anos, de forma que poucas amostras compostas atendam a necessidade fidedignamente. Com exceção das zonas 4 e 6 (Figura 5), todas as amostras, mesmo com a variabilidade das médias das diferentes densidades amostrais, os valores representativos de cada zona estavam na mesma classe de disponibilidade de K; assim, pequenas variações no valor médio ao se utilizar um número reduzido de pontos amostrais pode não influenciar o diagnóstico da fertilidade do solo e a dose final de prescrição de fertilizante.

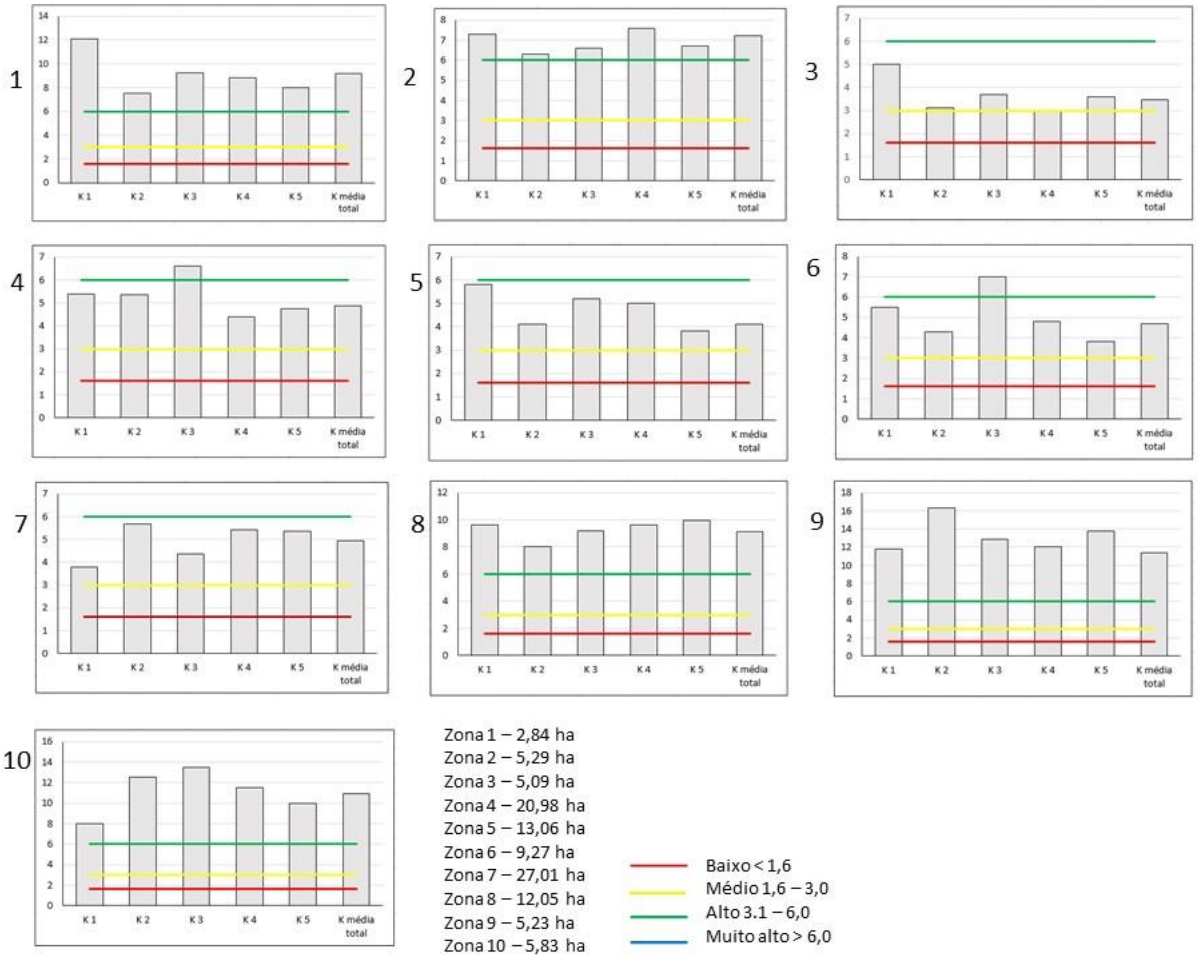


FIGURA 5. Valores médios dos teores de potássio (K) para todas as zonas (1-10), seguindo interpretação de Cantarella et al (2022), em função do número de subamostras, além da representação do valor médio representado pela média de todas as amostras da grade densa.

O teor de argila, por sua vez, apresentou bons resultados em termos de redução do erro médio absoluto (MAE), sendo que a amostragem em zonas conseguiu reduzir esse erro em comparação aos métodos convencional e ao mapeamento a partir da média densa dentro da zona (Figura 4a). Quando comparada a amostragem por zonas com a grade esparsa, ficou explícito que, mesmo com baixa densidade amostral, a grade esparsa teve melhores resultados (Figura 4a). Essa melhora pode ser explicada pela alta dependência espacial da argila, que, mesmo em baixa densidade amostral, foi capturada (Tabela 3). Nesta área, o comportamento espacial da argila é o oposto do fósforo: possui alta dependência espacial, o que proporciona agrupamento espacial e, por consequência, bom resultado do mapeamento por zonas, desde que as variáveis auxiliares utilizadas permitam isso. Como utilizamos as classes de solo e a suscetibilidade magnética, era esperado esse bom resultado para argila. Quando comparamos os teores de argila em função do número de subamostras, vimos que,

entre as coletas de 2 a 5 pontos por zona, a variação no MAE foi pequena, na faixa de 55 g/kg de argila, já que a amplitude observada para a área foi de 108 a 750 g/kg (Tabela 1). Assim, como a argila possui alto agrupamento espacial, a coleta de apenas duas amostras por zona já entrega um resultado satisfatório. A metodologia proposta permitiu criar zonas com textura argilosa e muito argilosa, ficando apenas a zona 3 com textura arenosa (Figura 6). Dependendo da mineralogia do solo, os dados de suscetibilidade magnética (SM) têm sido fortemente correlacionados com os teores de areia e argila, especialmente quando apresentam minerais magnéticos (Silva et al. 2016; Curi et al. 1990). Com isso, ao criarmos as zonas homogêneas de SM, constatamos que elas foram eficientes em representar as zonas de teores de argila. Devido à alta dependência espacial (Tabela 2), a metodologia de agrupamento permitiu gerar zonas com essa homogeneidade. A semelhança das médias dos valores de argila entre os diferentes cenários de subamostragem indica que, a partir de um ponto amostral composto no interior da zona, é possível representar as características físicas locais. Diferentemente dos atributos químicos, a variabilidade em curtas distâncias para a textura é mais estável, o que pode reduzir as chances de, com apenas um ponto amostral, haver coleta sub ou superestimada. Uma única ressalva é que, no caso de coletar apenas uma ou poucas subamostras, elas sejam mais centradas na área de cada zona, buscando evitar possíveis zonas de transição, as quais podem não ter sido bem delimitadas pela análise de agrupamento realizada...

TABELA 3. Parâmetros dos variogramas (a: alcance - m, c0: efeito pepita, c1: contribuição) e da validação cruzada (r2 e RMSE entre predito e observado) para os valores de P, K e Argila disponíveis para a grade esparsa.

Atributo	***a***	**c0**	**c1**	**r2**	**RMSE**
P	500	280	120	0,01	19,22
K	400	1,8	2,7	0,63	1,88
Argila	800	1000	8000	0,73	51,29

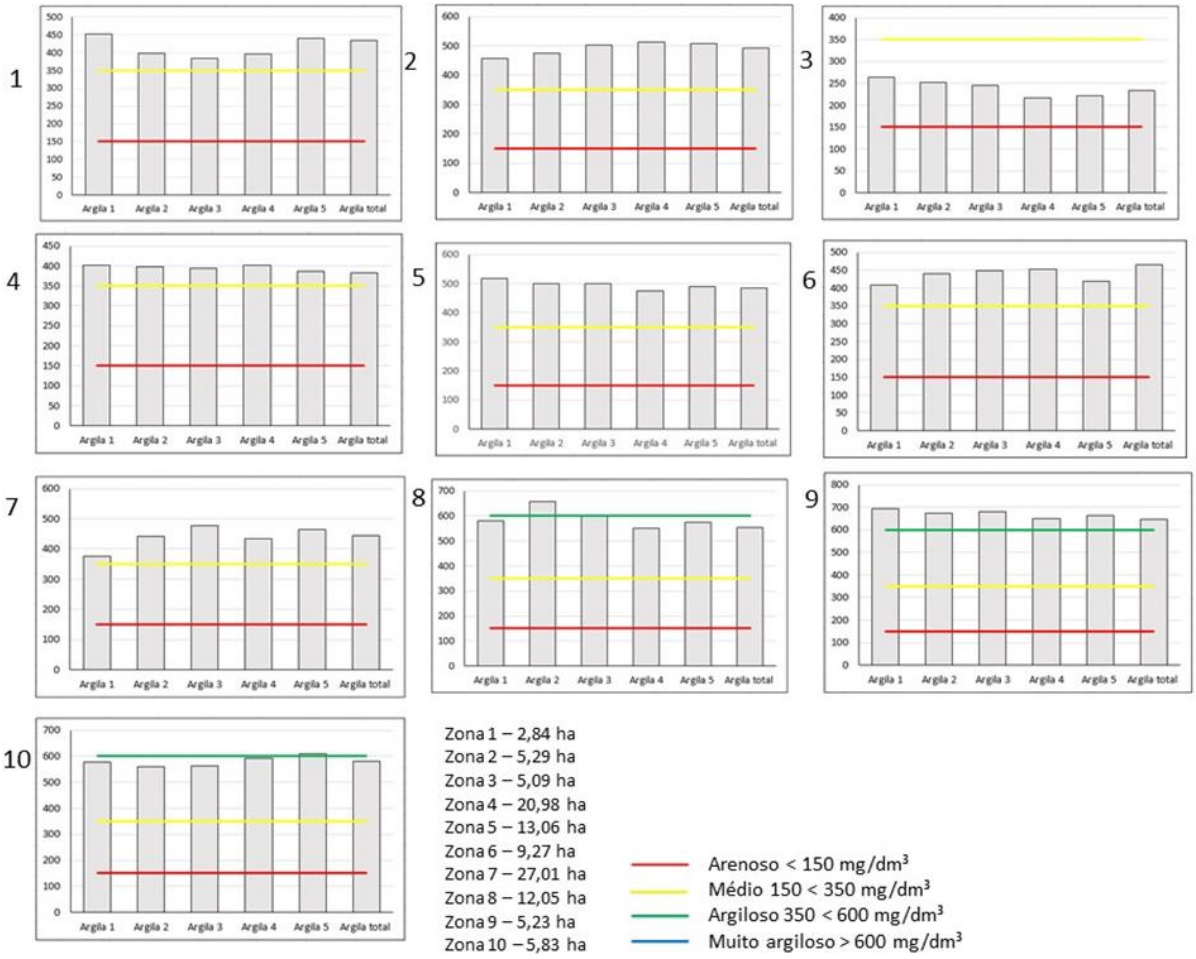


FIGURA 6. Valores médios dos teores de Argila para todas as zonas (1-10), seguindo recomendações da Embrapa Solos (2018), em função do número de subamostras, além da representação do valor médio representado pela média de todas as amostras da grade densa.

CONCLUSÃO

A amostragem por zonas para a caracterização do potássio do solo apresentou menores erros de predição do que a forma convencional e a grade regular esparsa. São indicados pelo menos 4 pontos amostrais compostos para representar o potássio dentro da zona; no entanto, para zonas menores que 13 hectares, podem ser adotados 2 ou 3 pontos amostrais. Assim, apesar de ser necessário estender o estudo a novas áreas, constatamos que a metodologia proposta é mais eficiente que a grade esparsa, além de reduzir o número de amostras necessárias para gerar mapas interpolados desse atributo do solo.

Como as variáveis auxiliares apresentam alta relação com argila, o resultado das zonas se mostrou muito superior à amostragem média convencional. Apesar de apresentar maior erro do que a amostragem em grade esparsa, ela atende satisfatoriamente ao mapeamento desse atributo, pois não há alterações significativas das classes texturais.

No caso de atributos do solo com fraca dependência espacial, a aleatoriedade dos valores amostrais e a alta variabilidade das amostras tornam tanto o método de krigagem quanto a criação de zonas ineficientes. Este cenário de mapeamento é desafiador, já que não se sabe, a priori, qual a dependência espacial dos atributos

AGRADECIMENTOS

Agradecemos à Fazenda São José, pela disponibilização da área de estudo e suporte à experimentação e à FAPESP pelo apoio financeiro a essa e outras pesquisas, processo n° 2023/02592-4 e 2022/03160-8.

REFERÊNCIAS

AMARAL, L. R. D.; JUSTINA, D. D. D. Spatial dependence degree and sampling neighborhood influence on interpolation process for fertilizer prescription maps. **Engenharia Agrícola**, v. 39, p. 85-95, 2019.

CANTARELLA, H.; QUAGGIO, J. A.; MATTOS JUNIOR, D.; BOARETTO, R. M.; RAIJ, B. V. (ed.). Boletim 100: Recomendações de adubação e calagem para o estado de São Paulo.Campinas: Instituto Agronômico, 2022. 489 p.

CHERUBIN, M. R., SANTI, A. L., EITELWEIN, M. T., AMADO, T. J. C., SIMON, D. H., & DAMIAN, J. M. Dimensão da malha amostral para caracterização da variabilidade espacial de fósforo e potássio em Latossolo Vermelho. **Pesquisa Agropecuária Brasileira**, v. 50, p. 168-177, 2015.

CÓRDOBA, M. A.; BRUNO, C. I.; COSTA, J. L.; PERALTA, N. R.; BALZARINI, M. G. Protocol for multivariate homogeneous zone delineation in precision agriculture. **Biosystems engineering,** v. 143, p. 95-107, 2016.

CURI, N.; LIMA, J. M.; ANDRADE, H.; GUALBERTO, V. Geomorfologia, física, química e mineralogia dos principais solos da região de Lavras (MG). **Ciência e Prática**, v. 14, n. 2, p. 297-307, 1990.

MATOS, A. P. D.; MATIAS, S. S. R.; NUNES, R. K. L.; MORAIS, E. M.; TAVARES FILHO, G. S. Soil management of limed areas cultivated with banana identified by magnetic susceptibility. **Revista Ceres**, v. 70, p. 17-24, 2023.

MOLIN, J. P.; DO AMARAL, L. R.; COLAÇO, A. Agricultura de precisão. Oficina de textos, 2015.

OLDONI, H.; TERRA, V. S. S.; TIMM, L. C.; JÚNIOR, C. R.; MONTEIRO, A. B. Delineation of management zones in a peach orchard using multivariate and geostatistical analyses. **Soil and Tillage Research,** v. 191, p. 1-10, 2019.

SILVA, S. H. G.; WEINDORF, D. C.; PINTO, L. C.; FARIA, W. M.; JUNIOR, F. W. A.; GOMIDE, L. R.; CURI, N. Soil texture prediction in tropical soils: A portable X-ray fluorescence spectrometry approach. **Geoderma**, v. 362, p. 114136, 2020.

SOLOS, EMBRAPA.Sistema brasileiro de classificação de solos. **Centro Nacional de Pesquisa de Solos:** Rio de Janeiro, v. 5, 2018.

SILVA, S. H. G.; POGGERE, G. C.; MENEZES, M. D. D.; CARVALHO, G. S.; GUILHERME, L. R. G.; CURI, N. Proximal sensing and digital terrain models applied to digital soil mapping and modeling of Brazilian Latosols (Oxisols). **Remote Sensing**, v. 8, n. 8, p. 614, 2016.

WANG, Y.; QI, Q.; BAO, Z.; WU, L.; GENG, Q.; WANG, J. A novel sampling design

considering the local heterogeneity of soil for farm field-level mapping with multiple

soil properties. **Precision Agriculture**, v. 24, n. 1, p. 1-22, 2022.

DANOS POR GEADA EM CAFEEIROS DE DIFERENTES IDADES UMA AVALIAÇÃO COM AERONAVE REMOTAMENTE PILOTADA

GISLAYNE FARIAS VALENTE [1]; GABRIEL ARAUJO E SILVA FERRAZ [2]; FELIPE SCHWERZ [3]; RAFAEL DE OLIVEIRA FARIA [4]; MICHEL MARTINS ARAÚJO SILVA [5]

[1]Bolsista. UFLA. Universidade Federal de Lavras; [2]Docente. UFLA. Universidade Federal de Lavras; [3]Docente. UFLA. Universidade Federal de Lavras; [4]Docente. UFLA. Universidade Federal de Lavras; [5]Estudante. UFLA. Universidade Federal de Lavras

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Uma análise precisa dos prejuízos ocasionados por geadas nas plantações de café pode auxiliar a desenvolver práticas agronômicas eficientes frente às mudanças climáticas. O emprego de aeronave remotamente pilotada e a avaliação de índices de vegetação emergem como métodos promissores para avaliar os efeitos dos danos de geada na produção de café. Nesse contexto, objetivou-se avaliar os danos de geada na cultura do café, utilizando índices de vegetação, em plantações de diferentes idades e áreas de risco climático. Avaliaram-se três plantações de café localizadas em Minas Gerais, Brasil, com idades de um, dois e oito anos na data em que ocorreu a geada. As áreas foram subdivididas em alto risco e baixo risco de danos por geada. Os dados e imagens aéreas, incluindo imagens RGB e multispectrais, foram coletados por uma aeronave remotamente pilotada, três dias após a ocorrência da geada. As diferenças estatísticas dos dados de danos por geada (DG) nas áreas estudas, foram obtidas com base no teste não paramétrico de comparação. O índice de vegetação NDVI foi testado para evidenciar a variabilidade espacial dos danos por geada. O plantio de um ano de idade foi mais afetado pelos danos foliares de geada. A área de alto risco apresentou maior porcentagem de danos em todas as idades de plantio. O uso do NDVI foi eficiente para visualizar os danos por geada nos plantios.

PALAVRAS-CHAVE: cafeicultura de precisão; imagem multiespectral; agrometeorologia

ABSTRACT

An accurate analysis of the damage caused by frost in coffee plantations can help to develop efficient agronomic practices in the face of climate change. The use of remotely piloted aircraft and the assessment of vegetation indices emerge as promising methods for evaluating the effects of frost damage on coffee production. In this context, the objective was to evaluate frost damage to coffee crops, using vegetation indices, in plantations of different ages and areas of climatic risk. Three coffee plantations located in Minas Gerais, Brazil, aged one, two and eight years old on the date the frost occurred, were evaluated. The areas were subdivided into high risk and low risk of frost damage. Aerial data and images, including RGB and multispectral images, were collected by a remotely piloted aircraft three days after the frost occurred. Statistical differences in frost damage (DG) data in the studied areas were obtained based on the non-parametric comparison test. The NDVI vegetation index was tested to highlight the spatial variability of frost damage. The one-year-old planting was most affected by frost foliar damage. The high-risk area showed a higher percentage of damage at all planting ages. The use of NDVI was efficient to visualize frost damage in plantations.

KEYWORDS: precision coffee; multispectral image; agrometeorology

INTRODUÇÃO

A cafeicultura do Brasil se destaca globalmente por sua produção e exportação. No entanto, os danos provocados por geadas nas plantações de café podem ter um impacto significativo na redução da qualidade e quantidade da safra (ROSISCA et al., 2015). Grande parte da produção nacional é oriunda do sul de Minas Gerais, onde a geada é uma preocupação para os agricultores e historicamente é associada a calamidades de proporções nacionais que afetaram a cafeicultura (BRAGA et al., 2021). A geada é um fenômeno microclimático definido quando a temperatura cai abaixo do ponto de congelamento de água. Seus feitos nocivos em cafeeiros, resultam no congelamento de água em os tecidos celulares, formação de gelo dentro da célula levando ao rompimento das paredes celulares e necrose do tecido vegetal (Malagi et al., 2015).

Em condições de terrenos inclinados, o ar frio que se acumula na superfície tende a fluir para baixo e acumular na parte inferior da encosta em depressões ou vales, com isso as geadas tem um efeito muito maior nessa localidade (CAMARGO; CAMARGO, 2004). Por isso, o impacto da topografia do terreno é um fator importante que pode gerar variabilidade climática, gerando áreas com diferentes riscos climático no plantio (KUMHÁLOVÁ; MOUDRÝ, 2014). A cafeicultura em Minas Gerais se estende entre altitudes de 800 a 1000 metros, ocupando terrenos com declives que variam de planos a ondulados, com inclinações entre 3 e 20%. A declividade dessas áreas está intimamente ligada à incidência de geadas. Nessas regiões, os episódios de geada estão principalmente correlacionados a fatores climáticos como latitude, altitude, continentalidade e relevo (ALVARES et al., 2018).

As lavouras de cafeeiros necessitam de avaliações de suas condições por meio de monitoramento e detecção de danos após a ocorrência da geada. Isso é necessário para quantificar o estresse e os prejuízos causados por esse evento, fornecendo informações essenciais para apoiar a tomada de decisões, como a necessidade de podar as plantas danificadas e aplicar fertilizantes para preservar as folhas que não foram afetadas (MARIN et al., 2021).

OBJETIVOS

Nesse contexto o objetivo deste estudo foi avaliar os danos de geada na cultura do café, utilizando índice de vegetação, em plantações de diferentes idades e áreas de risco climático.

MATERIAL E MÉTODOS

O estudo foi realizado na Fazenda Bom Jardim, localizada em Santo Antônio do Amparo, Minas Gerais, Brasil, com as coordenadas geográficas 21°00'58.9"S e 44°55'24.9"W, a uma altitude de 950 metros acima do nível do mar. Três áreas experimentais de plantio de café (Coffea arabica L.) foram utilizadas, com idades de um ano, dois anos e oito anos. A Área de 1 ano abrangia 31.966 m² e era plantada com cafeeiros das cultivares Catucaí e Arara.

A Área de 2 anos consistia em 19.546 m² de cafeeiros da cultivar Catuaí Amarelo, enquanto a Área de 8 anos era cultivada com cafeeiros da cultivar Catucaí vermelha IAC 144, em uma extensão de 35.176 m². Cada uma das áreas foi subdividida utilizando a metodologia descrita por Marin et al. (2021) para classificar o grau de risco de danos nas plantas como baixo (B) ou alto (A) (FIGURA 1).

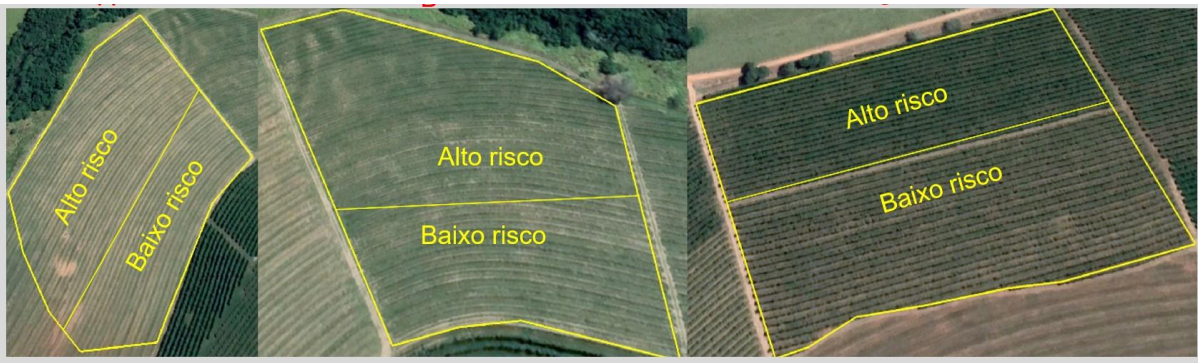


FIGURA 1. Áreas utilizadas no experimento com um ano de idade (a), dois anos de idade (b) e oito anos de idade (c) em função das zonas de risco climáticos.

Essa classificação levou em consideração critérios que avaliam a variação de altitude e topografia, incluindo variações na inclinação do terreno e, principalmente, a configuração do terreno. As imagens foram obtidas usando uma aeronave pilotada remotamente (RPA) e uma câmera multiespectral acoplada. A RPA utilizada foi a 3DR Solo comercial (3D Robotics, Berkeley, CA, EUA). A avaliação visual *in loco* de danos causados por geada em cafeeiros foi realizada de acordo com metodologia descrita por Marin et al. (2021). Os dados referentes aos danos por geadas foram submetidos a análise de variância e teste Tukey.

RESULTADOS E DISCUSSÃO

Os resultados do teste Tukey para os dados de dano de geada (DG) nas idades de plantio e áreas de risco climático estão apresentados na Tabela 1.

TABELA 1. Resultado do teste de comparação de médias para avaliar o dano de geada (DG) nos plantios.

	Zonas de favorabilidade climática			
Idade do Plantio	Baixo risco		Alto risco	
	DG (%)	DP	DG (%)	DP
Oito anos	4 A a	4	39 A b	11
Dois anos	12 B a	5	50 B b	9
Um ano	6 AB a	2	88 C b	8

Médias seguidas de mesma letra maiúscula na coluna e mesma letra minúscula na linha não diferem entre si pelo teste de Tukey ($p<0,05$).

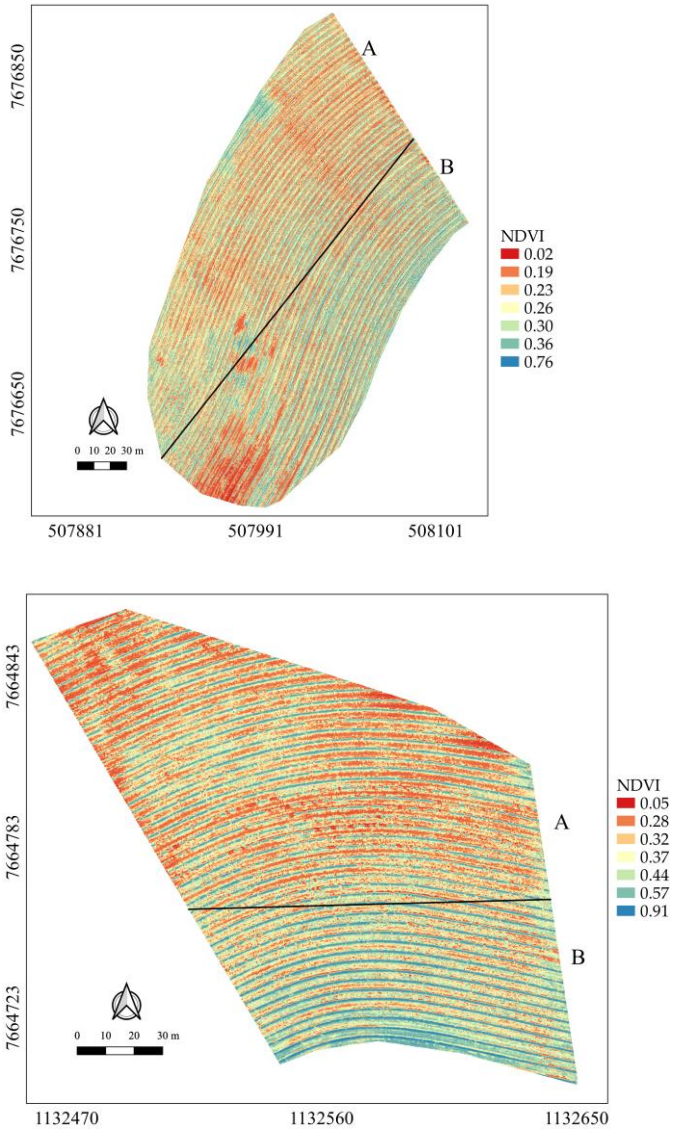
Médias seguidas de mesma letra maiúscula na coluna e mesma letra minúscula na linha não diferem entre si pelo teste de Tukey ($p<0,05$).

Os resultados indicaram que os maiores danos foram observados em áreas de alto risco climático para plantas com um ano de idade, alcançando aproximadamente 88%. Para as plantas com dois e oito anos, os danos foram de 50% e 39%, respectivamente. Nas áreas de baixo risco climático, houve pouca variação entre as diferentes idades, com valores próximos a 10%.

Os danos por geada podem ser intensificados em função de vários fatores, sendo que o estágio de desenvolvimento da planta e a configuração do relevo são determinantes na intensidade dos danos observados (Marin et al.,2021).

A análise ressalta a relação entre a idade do plantio, as zonas de risco climático e os sintomas de danos foliares nas lavouras de café. A menor incidência de danos nas plantas de oito anos, em ambas as zonas de risco, sugere uma influência significativa da idade na saúde e desenvolvimento das plantas. Além disso, a maior ocorrência de danos na zona de alto risco destaca a importância das condições climáticas favoráveis e a idade das plantas na severidade dos danos causados pela geada nos cafeeiros.

Os mapas de índices de vegetação foram gerados para visualização de DG em cafeeiros. Na Figura 2 estão apresentados os mapas dos índices de vegetação NDVI nos plantios de um ano, dois anos e oito anos de idade, respectivamente.



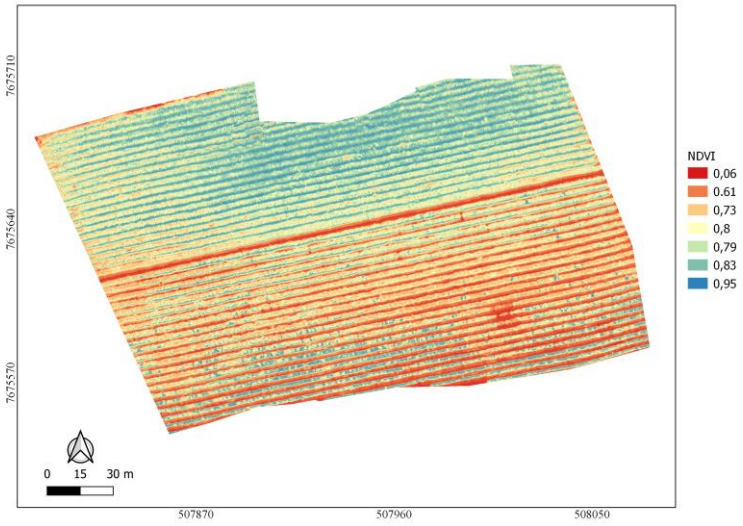


FIGURA 2. Mapas de NDVI nos plantios de um ano (a), dois anos (b) e oito anos (c) de idade. A: alto risco climático; B: baixo risco climático.

Nos mapas de NDVI (FIGURA 2) observa-se de maneira evidente a variação no vigor vegetativo entre as áreas de risco climático, destacando a sensibilidade do índice na avaliação imediatamente após a geada. Esse índice tem sido amplamente utilizado como ferramentas importantes para o monitoramento da vegetação, tanto como um indicador diagnóstico de desenvolvimento fenológico e saúde da planta (ALLEVATO et al., 2019). Estudando índices de vegetação na identificação de variáveis biótica e abióticas em cafeeiro, Marin et al. (2019) verificaram que valores dos índices de vegetação tendem a diminuir em plantas com menor vigor vegetativo, pois esses são calculados a partir das diferenças de reflectância entre a banda do infravermelho próximo e as bandas do visível e do infravermelho médio dessa forma, reduzido os valores dos índices de vegetação. Os danos de geada nas folhas do cafeeiro induzem estresse na planta, resultando em alterações físicas e químicas. Isso afeta a capacidade da planta de interceptar a radiação eletromagnética, o que por sua vez influencia sua assinatura espectral. Portanto, o Índice de Vegetação por Diferença Normalizada (NDVI) mostrou-se sensível para a detecção desses danos.

CONCLUSÃO

O NDVI revelou ser sensível ao evidenciar as diferenças entre as plantas afetadas pelas zonas de alto e baixo risco logo após a geada. Os danos causados pela geada na cultura do café foram influenciados tanto pela zona de risco climático quanto pela idade da planta. Os maiores danos foram observados nas áreas consideradas de alto risco climático.

AGRADECIMENTOS

Os autores agradecem o apoio financeiro das agências de fomento CNPq (projeto 310186/2023-4), FAPEMIG (project APQ-00661-22), EMBRAPA Café - Consórcio Pesquisa Café (project 10.18.20.041.00.00) e CAPES, e ao Programa de Pós-Graduação em Engenharia Agrícola da UFLA pelo apoio à pesquisa.

REFERÊNCIAS

REFERÊNCIAS

ALLEVATO, E. et al. Canopy damage by spring frost in European beech along the Apennines: effect of latitude, altitude and aspect. **Remote Sensing of Environment**, v. 225, p. 431-440, 2019.

BRAGA, G. B., et al. Frost Risk and Rural Insurance in Brazil. **Revista Brasileira de Meteorologia**, v. 36, n. 4, 703-711, 2021.

ALVARES, C. A.; SENTELHAS, P.C.; STAPE, J.L. Modeling monthly meteorological and agronomic frost days, based on minimum air temperature, in Center-Southern Brazil. **Theor Appl Climatol**, v. 134, p. 177-191, 2018.

CAMARGO, P.; CAMARGO, M. B. Frost in Coffee Crops: Frost Characteristics, Damaging Effects on Coffee and Alleviation Options. In Coffee: Growing, Processing, Sustaining Production: **A Guidebook for Growers, Processors, Traders, and Researchers** (Ebook: ed. 1 ed., cap 11, p. 355-369, 2004.

MARIN, D. B. et al. Unmanned aerial vehicle to evaluate frost damage in coffee plants. **Precision Agriculture**, v. 22, p.1845-1860, 2021.

KUMHÁLOVÁ, J.; MOUDRÝ, V. Topographical characteristics for precision agriculture in conditions of the Czech Republic. **Applied Geography**, v. 50, p. 90-98. 2014.

Rosisca. J. R. et al. Danos foliares em genótipos de café expostos a temperaturas negativas. IX Simpósio de Pesquisa dos Cafés do Brasil, Curitiba - PR, 24 a 26 de junho de 2015.

ACOMPANHAMENTO DO DESENVOLVIMENTO DE EUCALIPTO POR SENSORIAMENTO ORBITAL

Gabriel Ferraz Toledo [1]; Marcelo Chan Fu WEI [2]; José Paulo Molin [3]
[1]Graduando em Engenharia Agronômica, Estudante, Lab. de Agricultura de Precisão, Depto. De Biossistemas. Avenida Pádua Dias, 11, 13418-900, Piracicaba, São Paulo, Brasil. Universidade de São Paulo - Escola Superior de Agricultura 'Luiz de Queiroz; [2]Eng.º Agrônomo, Doutorando, Lab. de Agricultura de Precisão, Depto. Engenharia de Biossistemas. Avenida Pádua Dias, 11, 13418-900, Piracicaba, São Paulo, Brasil. Universidade de São Paulo - Escola Superior de Agricultura 'Luiz de Queiroz; [3]Eng.º Agrícola, Professor, Lab. de Agricultura de Precisão, Depto. Engenharia de Biossistemas. Avenida Pádua Dias, 11, 13418-900, Piracicaba, São Paulo, Brasil. Universidade de São Paulo - Escola Superior de Agricultura 'Luiz de Queiroz

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
A produção florestal brasileira tem se elevado em nível de importância nos últimos anos, com o aumento da demanda por matérias primas e principalmente por fontes de energia renováveis. A fim de suprir tal demanda, novas técnicas de gestão e tecnologias vêm sendo empregadas na silvicultura, com o objetivo de alcançar maior produtividade e lucratividade, porém de forma sustentável. Dentre os novos sistemas de gestão utilizados está a agricultura de precisão, que leva em consideração a variabilidade espacial e temporal do campo para melhorar a eficiência, especialmente na utilização de insumos agrícolas. Com isso surgem diversas oportunidades, como a possibilidade de acompanhar o desenvolvimento da cultura do eucalipto por meio de sensoriamento remoto, reduzindo o grau de complexidade e onerosidade da coleta de dados para o gerenciamento de florestas plantadas. Dessa forma, esse estudo propõe o acompanhamento do desenvolvimento da cultura a partir de índices vegetativos gerados com a utilização de dados orbitais, assim como analisar a viabilidade da aplicação desta técnica na silvicultura.

PALAVRAS-CHAVE: Landsat; NDVI; Índices vegetativos

ABSTRACT
Brazilian forest production has become increasingly important in recent years, with growing demand for raw materials and especially for renewable energy sources. In order to meet this demand, new management techniques and technologies are being employed in silviculture, with the aim of achieving greater productivity and profitability, but in a sustainable way. Among the new management systems used is precision agriculture, which takes into account the spatial and temporal variability of the field to improve efficiency, especially in the use of agricultural inputs. This opens up a number of opportunities, such as the possibility of monitoring the development of eucalyptus crops using remote sensing, reducing the complexity and cost of data collection for the management of planted forests. Therefore, this study proposes to monitor crop development using vegetation indices generated with the use of orbital data and also analyzing the feasibility of employing the technique in silviculture.

KEYWORDS: ;;

INTRODUÇÃO

Apesar do desenvolvimento tecnológico ter proporcionado ganho de produtividade na maior parte das atividades agrícolas, observa-se nos últimos anos, uma queda significativa na produtividade das florestas plantadas com árvores do gênero *Eucalyptus*. Segundo os dados dos relatórios anuais

oferecidos pela Industria Brasileira de Árvores (IBÁ), de 2014 até 2022, a produtividade anual das florestas plantadas caiu de 39 m³ para 32,7 m³ por ha. Nesse sentido, torna-se imprescindível a aplicação de sistemas de gestão e monitoramento para realizar correções de modo a aumentar a efetividade e a produtividade das florestas plantadas, como é o caso da Agricultura de Precisão (AP).

"A AP é uma estratégia de gestão que reúne, processa e analisa dados temporais, individuais e espaciais e os combina com outras informações para apoiar as decisões de gerenciamento de acordo com a variabilidade estimada para melhorar a eficiência no uso de recursos, produtividade, qualidade, rentabilidade e sustentabilidade da produção agropecuária." (ISPA, 2024). Dessa forma, a utilização desse sistema de gestão de forma ampla na cultura do eucalipto se torna um método importante para elevarmos a oferta de matérias primas e energia de forma sustentável.

A aplicação da AP depende da disponibilidade de dados e medições locais que suportem a tomada de decisão, sendo dependente da resolução espacial. Em florestas plantadas, a amostragem dos dados, principalmente relacionados à produtividade, é feita com o uso do inventário florestal (FLORIANO, 2021), estimativa de baixa resolução espacial que é extrapolada para uma extensa área e é considerada um processo caro e oneroso.

Como alternativa à coleta de dados em campo para monitoramento e planejamento florestal recorresse ao uso do sensoriamento remoto (SR) (KÄFER *et al*., 2018), que é definido como "obtenção de informações de um objeto sem existir um contacto físico com o mesmo, e muitas vezes à longas distâncias" SHIRATSUCHI *et al*., 2014). Entretanto, o SR é utilizado com dados de baixa resolução espacial, no caso, inventário florestal, podendo não representar fidedignamente o comportamento espacial da cultura.

Dessa forma, torna-se necessário utilizar camadas de dados de produtividade com maior resolução espacial juntamente com os dados do SR na tentativa de melhorar o entendimento dos padrões espaciais relacionados ao desenvolvimento da cultura.

OBJETIVOS

Analisar o desenvolvimento do eucalipto utilizando dados orbitais e mapas de produtividade em alta resolução espacial.

MATERIAL E MÉTODOS

O estudo foi realizado com dados de um talhão cultivado com *Eucalyptus grandis* localizado no estado de São Paulo, disponibilizados em DIAS (2021). A área está situada no município de Anhembi (coordenadas geográficas 22°54'57" de latitude Sul e 48°14'33" de longitude Oeste e dimensão de 18,56 ha, com solos classificados majoritariamente como neossolo), a floresta foi implantada em 2011 com um espaçamento entre linhas de 3,80 m e entre plantas de 2,10 m e colhida entre 10 de dezembro de 2018 e 07 de janeiro de 2019.

Com o intuito de remover pontos discrepantes do conjunto de dados de produtividade, foi realizada a filtragem com o uso do programa MapFilter 2.0 (Maldaner; Molin; Spekken; 2021) adotando os critérios a seguir: (a) filtragem global - limite de variação de 75% e (b) filtragem local - dependência espacial de 100 m e limite de variação de 25%. Após a filtragem, os dados foram interpolados pelo método da krigagem ordinária com grade de 30 m x 30 m pelo ajuste do modelo "linear com patamar".

Os dados orbitais foram obtidos da plataforma *Earth Explorer* com imagens de resolução espacial de 30 m x 30 m entre os anos de 2013 e 2018 com filtro de cobertura de nuvem de até 80% do sensor Landsat 8-9 OLI/TIRS C2 L2. A partir dos dados orbitais, foi calculado do índice de vegetação por diferença normalizada (NDVI - Eq. 1).

NDVI = (IV - V) / (IV + V) - Eq. 1,

onde, IV = Valor do fluxo radiante no comprimento de onda correspondente ao infravermelho próximo; V = Valor do fluxo radiante no comprimento de onda correspondente ao vermelho.

A análise descritiva dos dados foi realizada no conjunto de dados de produtividade e NDVI, seguida da análise de correlação de Pearson (r - Eq. 2). A partir dos resultados da correlação de Pearson, foram selecionados as cinco datas nas quais o NDVI índices que apresentou maiores correlações com a produtividade e foram gerados os seus mapas de superfície com o uso do programa QGIS 3,28 (QGIS Development Team, 2024) e *plugin* Smart-MAP (PEREIRA *et al*,2022).

$$r = \frac{\sum(x_i - \bar{x})(y_{i-}\bar{y})}{\sqrt{(\sum(x_i - \bar{x})^2)(\sum(y_i - \bar{y})^2)}}$$

- Eq. 2,

Onde, r = Coeficiente de correlação de Pearson; ? = Somatório; x? = Média aritmética simples dos valores de X; Y = Valor assumido pela variável dependente; y? = Média aritmética simples dos valores de y.

RESULTADOS E DISCUSSÃO

A partir dos dados temporais de NDVI de 2013 a 2018, observa-se que existe uma amplitude de valores por data, tendo maiores ou menores amplitudes. Esse fenômeno está associado à complexa interação fisiológica da cultura com as variáveis locais (i.e., pluviosidade, disponibilidade de nutrientes, entre outros) (Figura 1).

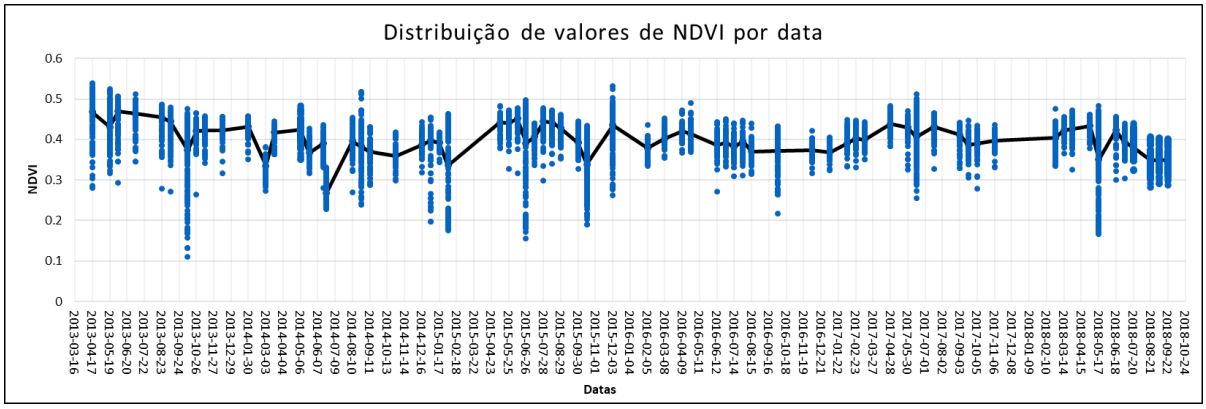


FIGURA 1. Gráfico de dispersão demonstrando os valores de NDVI para os pixels em cada dia avaliado no período.

Nota-se a discrepância dos valores médios de NDVI com relação aos esperados para a cultura do eucalipto, cujos valores são estimados entre 0,55 e 0,80 (Ferreira; Silva; Almeida; 2020, p.156) (Tabela 1). Essa discrepância condiz com a baixa produtividade atingida na área, como descrito por DIAS (2021), podendo ser atribuída ao baixo vigor da cultura, ocasionado provavelmente pela combinação de parâmetros como características químicas e físicas do solo, condições climáticas em períodos críticos da cultura, entre outros.

Parâmetros	Conjunto de dados de NDVI	Produtividade
Mínimo	0.11	171.09
Máximo	0.54	303.98
Média	0.40	233.67
Mediana	0.40	232.81
Desvio padrão	0.05	24.86

TABELA 1. Resultado das análises de estatísticas para o conjunto de dados.

Foi possível observar também uma variação sazonal do NDVI, ocasionada possivelmente pelo regime hídrico da região, aliado às características fisiológicas da cultura do eucalipto, que apresenta desfolhamento no outono e crescimento foliar na primavera, como aponta Manzatto (2018). Esse fator pode estar contribuindo com a rápida mudança dos valores de NDVI e dos índices de correlação entre datas próximas.

A partir da análise de correlação linear de Pearson (Figura 2), obtivemos 32 datas nas quais o valor de correlação não foi significativo e 38 datas com valores significativos, todas apresentando fraca correlação ($r < 0,3$), sendo 23 de valor positivo e 15 de valor negativo. Esses resultados são opostos aos encontrados por MACEDO *et al*. (20I7), na qual identificaram alta correlação negativa entre o NDVI e o volume de madeira estimado nas áreas. Porém ressalta-se que em seu estudo, ele foi conduzido com uma única imagem de satélite e resolução espacial distinta. No entanto, Manzatto (2018), identificou maior vigor e densidade em talhões nos quais a cultura apresentava maiores índices de NDVI. Essas divergências podem indicar que as características do sistema sensor utilizado para a obtenção dos dados influencia diretamente no cálculo dos índices vegetativos e consequentemente, na correlação entre as variáveis.

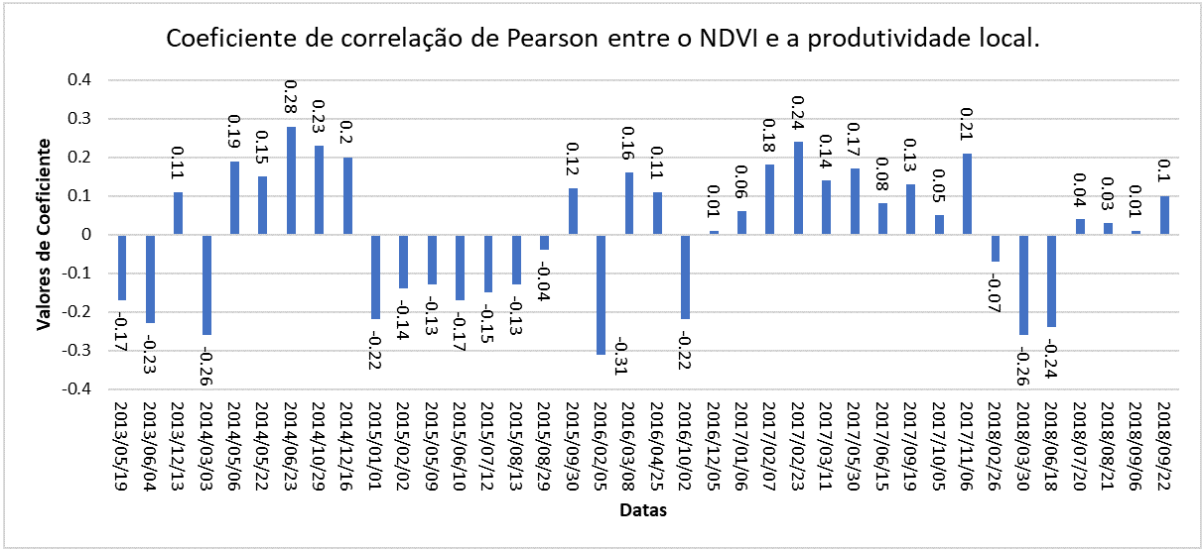


FIGURA 2. Dias cujo valor do coeficiente de correlação de Pearson foi significativo.

Comparando visualmente os mapas de produtividade e os cinco NDVI com maior correlação absoluta, observa-se que temporalmente existe uma variação entre os padrões de NDVI e que algumas regiões apresentam padrões parecidos com o mapa de produtividade. Porém, o padrão é dependente da data da imagem, o que pode afetar positivamente e/ou negativamente a interpretação dos resultados.

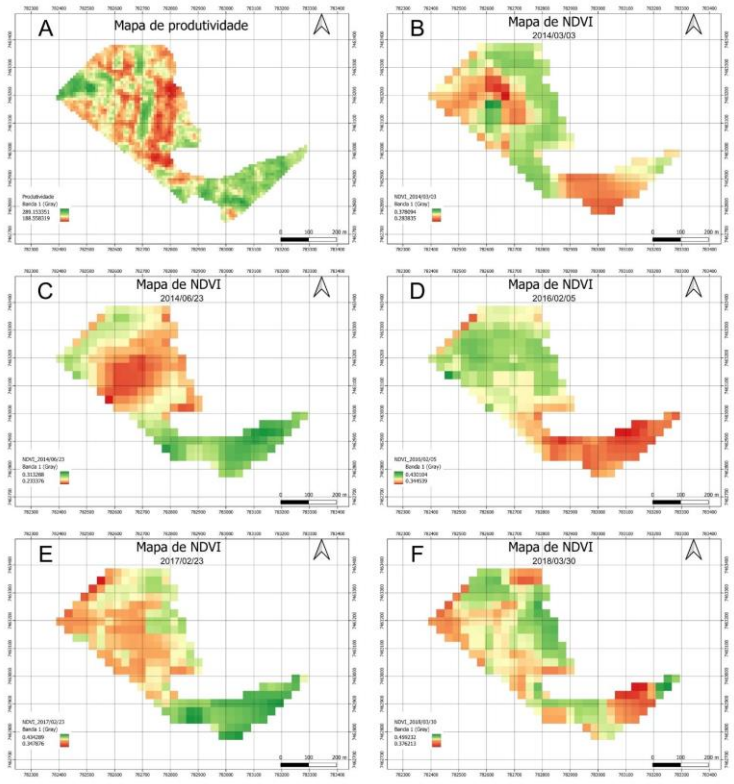


FIGURA 3. Mapas comparativos para maiores valores absolutos de correlação entre NDVI e produtividade.

A partir dos resultados, nota-se que o uso dos dados de NDVI temporalmente demonstra o comportamento do desenvolvimento da cultura, porém ela não necessariamente está linearmente correlacionada com a produtividade. Isso ressalta a necessidade do uso de camadas de dados adicionais para melhorar a interpretação do entendimento da variabilidade da lavoura em maior resolução espacial e/ou outros índices de vegetação. Além disso, ressalta-se que o uso de modelos não lineares e/ou modelos de regressões múltiplas lineares na tentativa de explicar os efeitos de outras variáveis na produtividade deve ser também considerado.

CONCLUSÃO

O NDVI, para a área e no período do estudo não demonstrou forte correlação linear com a produtividade e, portanto, apresenta pouca aplicabilidade para o monitoramento do desenvolvimento da cultura do eucalipto e para o gerenciamento da cultura.

Recomenda-se realizar as análises para diferentes índices vegetativos e outras fontes de dados, obtidos por diferentes sistemas sensores como o satélite Sentinel, para averiguar as causas da baixa efetividade da técnica na área.

REFERÊNCIAS

BERNARDI, A. C. et. Al. Agricultura de precisão: resultados de um novo olhar. Brasília, DF: Embrapa, 2014. P. 58-73. Disponível em: http://www.alice.cnptia.embrapa.br/alice/handle/doc/1001965. Acesso em: 28 mar. 2024

DIAS, Rafael Donizetti. Avaliação da variabilidade espacial em plantações de eucalipto. Dissertação (Mestrado) - Curso de Engenharia de Sistemas Agrícolas, Departamento de Biossistemas, Escola Superior de Agricultura "Luiz de Queiroz". Piracicaba, p.88. 2021.

DINIZ, J. M. F. S. et al. Aplicação de parâmetros polarimétricos e interferométricos derivados de imagens alos/palsar-2 para a estimativa de volume de madeira em florestas plantadas de Eucalyptus sp. Pinus sp. in: anais do xx simpósio brasileiro de sensoriamento remoto, Florianópolis, p. 635-638. 2023.

FERREIRA, G. H. C.; SILVA, L. A. P.; ALMEIDA, R. P. Mapeamento do uso e cobertura do solo e comportamento do NDVI para diferentes usos da terra em áreas de cerrado no norte de minas gerais . Revista Tocantinense de Geografia, [S. l.], v. 9, n. 18, p. 143-159, 2020. DOI: 10.20873/rtg.v9n18p143-159. Disponível em: https://sistemas.uft.edu.br/periodicos/index.php/geografia/article/view/9213. Acesso em: 4 abr. 2024

FLORIANO, Eduardo Pagel. Inventário florestal. Edição do Autor. Rio Largo, AL: Centro de Ciências Agrárias: Universidade Federal de Alagoas, 2021. 135 p. ISBN: 978-65-00-21723-0.

IBÁ (Org.). Relatório Ibá 2014. São Paulo, SP: Indústria Brasileira de Árvores, 2014. 100 p. Disponível em: https://www.iba.org/datafiles/publicacoes/pdf/iba-2014-pt.pdf. Acesso em: 20 fev. 2024

IBÁ (Org.). Relatório Ibá 2023. São Paulo, SP: Indústria Brasileira de Árvores, 2023. 91 p. Disponível em: https://iba.org/datafiles/publicacoes/relatorios/relatorio-anual-iba2023-r.pdf. Acesso em: 20 fev. 2024

ISPA - International Society of Precision Agriculture. 2024. Disponível em: https://www.ispag.org/about/definition. Acesso em: 27 fev. 2024.

KÄFER, P. S. et al. Modeling Pinus elliottii growth with multitemporal Landsat data: a study case in southern Brazil. Boletim de Ciências Geodésicas, v. 24, p. 286-299, 2018.

MACEDO, Fabrício Lopes de et al. Estimativa do volume de madeira para Eucalyptus sp. com imagens de satélite de alta resolução espacial. Scientia Forestalis, v. 45, n. 114, p. 237-247, 2017. .

MALDANER, L. F.; MOLIN, J. P.; SPEKKEN, M. Methodology to filter out outliers in high spatial density data to improve maps reliability. Scientia Agricola, v. 79, p. e20200178, 2021.

MANZATO, Caroline Lourenço. Estimativa de biomassa e estoque de carbono na cultura do eucalipto por meio de sensoriamento remoto, Bauru, 2018.

PEREIRA, G. W. et al. Smart-map: An open-source QGIS plugin for digital mapping using machine learning techniques and ordinary kriging. Agronomy, v. 12, n. 6, p. 1350, 2022.

QGIS Development Team, 2024. QGIS Geographic Information System. Open Source Geospatial Foundation Project. Disponível em: http://qgis.osgeo.org. Acesso em: 28 Mar. 2024.

ESTIMATIVA DO APORTE DE CARBONO PELA CULTURA DO TRIGO POR MEIO DO ÍNDICE DE VEGETAÇÃO POR DIFERENÇA NORMALIZADA

Thauhana Cássia Gasparotto Kuhn [1]; Alexandre Augusto Panisson [2]; Christian Bredemeier [3]; João Leonardo Fernandes Pires [4]; André Luis Vian [5]

[1]Bolsista. Faculdade de Agronomia, Campus do Vale - Av. Bento Gonçalves, 7712 - Agronomia, Porto Alegre - RS, 91540-000. UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL; [2]Mestrando. Faculdade de Agronomia, Campus do Vale - Av. Bento Gonçalves, 7712 - Agronomia, Porto Alegre - RS, 91540-000. UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL; [3]Professor. Faculdade de Agronomia, Campus do Vale - Av. Bento Gonçalves, 7712 - Agronomia, Porto Alegre - RS, 91540-000. UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL; [4]Pesquisador. Brasília, DF, Brazil. EMBRAPA; [5]Professor. Faculdade de, Campus do Vale - Av. Bento Gonçalves, 7712 - Agronomia, Porto Alegre - RS, 91540-000. UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Na cultura do trigo a adubação nitrogenada favorece o crescimento e desenvolvimento das plantas, uma vez que a absorção deste nutriente está intimamente relacionada com a absorção de carbono (C), refletindo na capacidade das plantas em acumular biomassa da parte aérea. O objetivo deste estudo foi estimar a aporte de C na cultura do trigo através da relação entre a absorção de N e acúmulo de biomassa da parte aérea utilizando o Índice de Vegetação por Diferença Normalizada (NDVI). Os experimentos foram conduzidos na Estação Experimental Agronômica da UFRGS e na Embrapa Trigo, em blocos ao acaso, com quatro repetições. Os tratamentos constaram com quatro cultivares, e foram realizadas as avaliações de absorção de C, absorção de N, biomassa da parte aérea e o NDVI ao longo do ciclo da cultura. A partir dos resultados, a utilização do NDVI como ferramenta para estimar o aporte de C na parte aérea do trigo no período entre V3 e florescimento, de forma a representar todo o seu ciclo de desenvolvimento, demonstrou ser eficaz, ao fazer uso das informações da relação entre absorção de N e acúmulo de biomassa.

PALAVRAS-CHAVE: *Triticum aestivum*; Acúmulo de carbono; Ambiente de produção

ABSTRACT

In wheat culture nitrogen fertilization favors the growth and development of plants, since the absorption of this nutrient is closely related to carbon absorption (C), reflecting the ability of plants to accumulate biomass in the aerial part. The objective of this study was to estimate the absorption of C in wheat culture through the relationship between N absorption and biomass accumulation of shoots using the Normalized Difference Vegetation Index (NDVI). The experiments were conducted at the Agronomic Experimental Station of UFRGS and at Embrapa Trigo, in randomized blocks, with four replications. The treatments consisted of four cultivars, and the evaluations of absorption of C, absorption of N, biomass of the aerial part and the NDVI throughout the crop cycle were performed. From the results, the use of NDVI as a tool to estimate the size of C in the aerial part of wheat throughout the development cycle proved to be effective when estimating the C sequestration from the relationship between N absorption and biomass accumulation.

KEYWORDS: *Triticum aestivum*; Carbon accumulation; Production environment

INTRODUÇÃO

A cultura do trigo (*Triticum aestivum* L.), é uma das culturas mais importantes do mundo, sendo amplamente cultivada devido à sua versatilidade, adaptabilidade a diferentes condições climáticas e

alto valor nutricional, desempenhando um papel essencial na segurança alimentar global (EMBRAPA, 1996).

O trigo necessita de uma boa disponibilidade de nitrogênio (N), sendo ele um dos macronutrientes mais importantes para as plantas, pois desempenha um papel fundamental na síntese de proteínas, no crescimento vegetativo e no desenvolvimento reprodutivo, além de fazer parte da molécula de clorofila. Este nutriente está intrinsecamente associado com o potencial produtivo do trigo, uma vez que afeta o número de perfilhos emitidos e sobreviventes, a quantidade de grãos por espiga, o peso e o teor de proteína dos grãos (MANTAI et al., 2016).

Desta forma, a adubação nitrogenada está intimamente ligada com o processo de fotossíntese através da molécula de clorofila presente nas folhas, onde o C é absorvido pelas plantas na forma de dióxido de carbono (CO2) durante a fotossíntese, formando compostos orgânicos que constituem os componentes estruturais das células vegetais, como as paredes celulares, membranas e organelas, além de desempenharem funções metabólicas e de armazenamento de energia (TAIZ et al., 2015; MARSCHNER, 2012).

A absorção de C acompanha o acúmulo de biomassa na parte aérea da planta, refletindo sua estreita relação com o crescimento vegetativo e, por este motivo, há uma relação com a disponibilidade e absorção de N. Portanto, essa relação entre a absorção de N e o sequestro de C demonstra que plantas com maior disponibilidade de N têm uma capacidade aumentada de aportar C na parte aérea, evidenciando a importância da adequada nutrição nitrogenada para o crescimento e desenvolvimento das plantas de trigo (DELOGU et al., 1998).

Nesse contexto, o Índice de Vegetação por Diferença Normalizada (NDVI) é amplamente utilizado na agricultura de precisão (AP) para correlacionar essas variáveis (ROUSE et al., 1973). Assim, com o emprego de ferramentas que estimem o aporte de C no sistema de produção das diferentes culturas produtoras de grãos, é possível inferir o potencial de sequestro de C em diferentes situações. Apesar da dinâmica do C nos sistemas de produção, a cultura do trigo, em função de sua composição estrutural do seu material orgânico, proporciona maior estabilidade do C quando comparada a outras culturas, como as leguminosas (ZHONG et al., 2015).

OBJETIVOS

O objetivo deste estudo foi estimar o aporte de C na cultura do trigo através da relação entre a absorção de N e acúmulo de biomassa da parte aérea utilizando o NDVI.

MATERIAL E MÉTODOS

Os ensaios de campo foram realizados nas safras agrícolas 2018 e 2019 em duas Regiões Homogêneas de Adaptação de Cultivo de Trigo (RHACT), na Estação Experimental Agronômica da UFRGS (RHACT 2) e na Estação Experimental da Embrapa Trigo (RHACT 1), Figura 1.

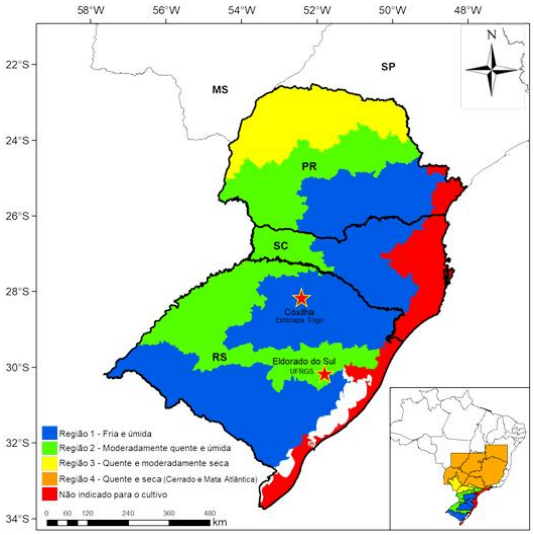


FIGURA 1. Localização das duas bases experimentais utilizadas para avaliação da cultura do trigo nas Regiões Homogêneas de Adaptação de Cultivo de Trigo (RHACT) do Estado do Rio Grande do Sul.

Características edafoclimáticas

A RHACT 1 situa-se na estação experimental da Embrapa Trigo, localizada no município de Coxilha/RS. O clima é subtropical de verão úmido quente, do tipo Cfa, conforme a classificação de Köppen (IPAGRO, 1979). A RHACT 2 situa-se a estação experimental agronômica da Universidade Federal do Rio Grande do Sul (EEA/UFRGS), localizada no município de Eldorado do Sul. O local onde está a EEA/UFRGS caracteriza-se como uma região fisiográfica da Depressão Central, possuindo clima subtropical de verão úmido quente, do tipo Cfa, conforme a classificação de Köppen (INMET, 2024) (Tabela 1). Anualmente, antes da realização dos ensaios a campo, foram realizadas amostragens de solo para caracterização química das áreas onde foram realizados os ensaios.

TABELA 1. Descrição das principais características edafoclimáticas dos locais onde foram conduzidos os experimentos para avaliação da cultura do trigo.

Município (Instituição)	Precipitação pluvial[1]	Tipo de solo[2]	Temperatura média[3] (ºC)		Altitude
	(mm)		Mínima	Máxima	(m)
Coxilha (EMBRAPA TRIGO)	1.788	Latossolo Vermelho Distrófico húmico	12,9	22,0	689
Eldorado do Sul (UFRGS)	1.440	Argissolo Vermelho Distrófico típico	14,0	25,0	46

[1]Precipitação pluvial média anual. [2]Solo predominante na região, segundo classificação proposta por Streck et al., 2008. [3]Temperatura do ar média anual no mês mais frio (mínima) e no mais quente (máxima) (INMET, 2024).

Descrição dos tratamentos e variáveis de crescimento

Os tratamentos constaram da avaliação de quatro cultivares (BRS Parrudo, BRS Reponte, TBIO Sossego e TBIO Toruk), dois locais (RHACT 1 e 2) e aplicação semanal de nitrogênio (N) para garantir a disponibilidade máxima para a cultura durante todo o ciclo com o objetivo de quantificar o acúmulo de C e absorção de N ao longo do ciclo da cultura. Os tratamentos utilizados tinham a finalidade de promover o máximo desenvolvimento das plantas, maximizando a produção de biomassa da parte aérea e a absorção de N. O manejo nutricional seguiu as indicações do Manual de Calagem e Adubação para o RS e SC objetivando um rendimento de grãos esperado de 4.000 kg ha^{-1}, o qual necessita uma dose total entre 110 e 140 kg ha^{-1} de N nas RHACT 1 e 2, respectivamente (CQFS-RS/SC, 2016).

O delineamento experimental utilizado foi de blocos ao acaso, com quatro repetições. A unidade experimental foi constituída de dez linhas de três metros de comprimento e com espaçamento entre linhas de 0,17 m, totalizando 5,1 m². Os ensaios foram conduzidos após a cultura da soja, uma vez que este é o sistema de sucessão que ocorre com maior frequência no RS. A densidade de semeadura foi de 300 sementes aptas por m^2, sendo a semeadura realizada no início do período indicado pelo Zoneamento Agrícola de Risco Climático (ZARC) para cada RHACT (RCBPTT, 2017).

Avaliações dos parâmetros de planta

A avaliação do NDVI foi realizada por meio da leitura da reflectância do dossel vegetativo com sensor óptico ativo GreenSeeker®. As leituras foram feitas com o equipamento posicionado paralelamente às linhas centrais da parcela, a 0,8 m acima do dossel. O NDVI foi calculado conforme a fórmula:

NDVI = (IVP-V) / (IVP+V)

Onde: V refere-se à reflectância no vermelho (680 nm); IVP refere-se à reflectância na região do infravermelho próximo (770 nm).

A coleta das amostras para avaliação da biomassa foi realizada ao longo do ciclo da cultura, mais especificamente, entre os estádios de desenvolvimento 3 (afilhos formados) até 11.3 (grão em massa dura) da escala de Feekes-Large (LARGE, 1954), totalizando 12 amostragens ao longo do ciclo. A biomassa na parte aérea foi quantificada por meio da amostragem de três linhas da área útil da parcela com 0,5 m de comprimento, totalizando área de 0,27 m². Posteriormente, as amostras foram secas em estufa de ar forçado à temperatura de 60 °C até atingir peso constante e após pesadas, foram extrapolados para kg ha^{-1}.

Carbono (C) e Nitrogênio (N) acumulado

Com os valores de biomassa seca na parte aérea, realizou-se o cálculo de estimativa para o aporte de C em kg ha^{-1}, onde foi considerado o valor médio de 45% de C como valor médio no tecido (PAULILO et al., 2015).

Aporte de carbono = biomassa seca na parte aérea x concentração de C no tecido

Onde: Biomassa seca refere-se a biomassa da parte aérea (kg ha^{-1}); Concentração de C no tecido (% no tecido).

As amostras foram moídas para a quantificação do teor de N no tecido vegetal, seguindo o método Kjeldahl (TEDESCO et al., 1995). O cálculo para definir a concentração de N absorvido no tecido foi realizado pela fórmula:

Quantidade de N absorvido (kg ha^{-1}) = Biomassa seca x concentração de N no tecido

Onde: Biomassa seca refere-se a biomassa a parte aérea (kg ha^{-1}); Concentração de N no tecido (% no tecido).

Análise estatística

Os dados foram submetidos à análise de variância ANOVA pelo Teste F, com auxílio do pacote estatístico SASTM (Statistical Analysis System - SAS 8.0). Posteriormente, foi realizada análise de regressão com os valores de NDVI, biomassa seca da parte aérea, aporte de C e N absorvido.

RESULTADOS E DISCUSSÃO

Ao longo do ciclo de desenvolvimento da cultura do trigo, observa-se que a biomassa e consequentemente de N e de C apresenta um rápido acúmulo depois dos 45 dias após a semeadura (DAS), que vai do período de perfilhamento até o início do enchimento de grãos (>105 DAS). Com o intuito de verificar o acúmulo de carbono ao longo do ciclo se construiu a Figura 2 A, B e C para os diferentes locais de estudo. Aos 105 dias após a semeadura a planta reduz o incremento em biomassa e realiza o enchimento de grãos a partir da atividade fotossintética, diminuindo assim, o acúmulo de N e de C (Figura 2A) (EMBRAPA, 2022).

Observa-se que o comportamento do acúmulo da absorção de N e de C segue o mesmo padrão que do acúmulo de biomassa (Figura 2B e 2C, respectivamente). A absorção de N pela cultura ocorre principalmente nos estádios iniciais, entre o perfilhamento (45 DAS) e o florescimento da cultura (100 DAS), caracterizando o período de máxima produção de grãos. O comportamento do sequestro de C foi similar ao do acúmulo de biomassa na parte aérea, visto que o sequestro de C foi estimado a partir dessa informação, considerando uma concentração de 45% de C na biomassa. Quando se analisa a relação C/N dos parâmetros de C e de N, observa-se que quanto maior for a absorção de N, maior é o sequestro de C pelas plantas, ou seja, plantas com adequada nutrição mineral possuem maior capacidade de sequestro de C (Figura 2D). Pode-se inferir que existe diferença de eficiência de uso de N entre os locais estudados, pois na RHACT 2, mesmo com uma menor quantidade de N acumulado, foi obtida a mesma biomassa que na RHACT 1, ainda que, para valores intermediários de acúmulo de C, precisa de menor quantidade de N (Figura 2D).

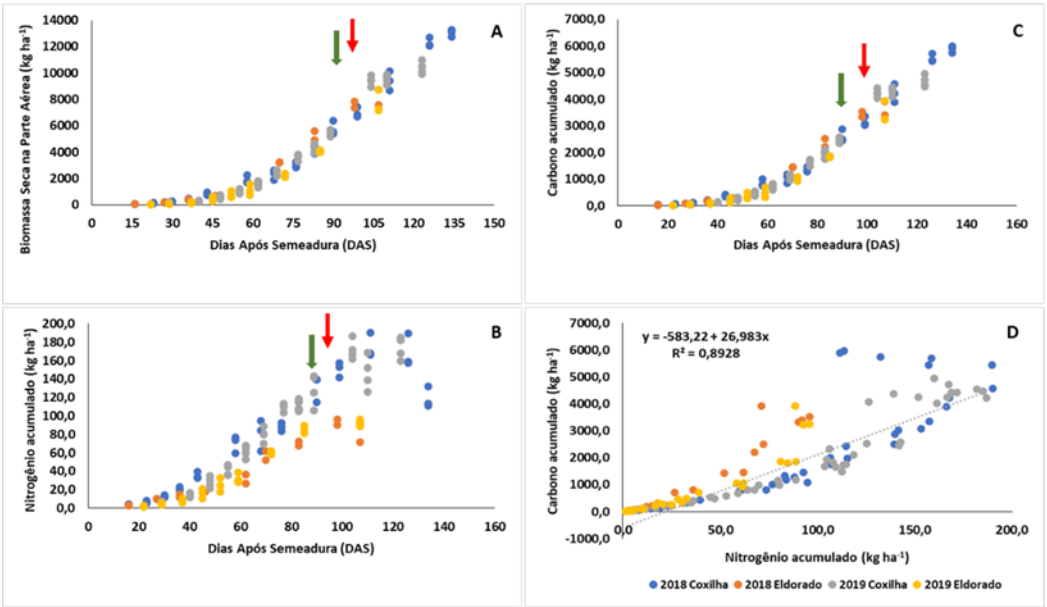


FIGURA 2. Comportamento do acúmulo de biomassa seca na parte aérea (A), de nitrogênio acumulado (B), de carbono acumulado (C) e da relação entre o acúmulo de biomassa e nitrogênio (D) de duas safras agrícolas (2018 e 2019) quatro cultivares (BRS Parrudo, BRS Reponte, TBIO Sossego

e TBIO Toruk.) Setas verdes e vermelhas indicam o período do florescimento da cultura do trigo nas RHACT 1 e 2 respectivamente.

Na Figura 3 são apresentadas as estimativas de acúmulo de biomassa e de N e o sequestro de C por meio do uso do NDVI. Observa-se que valores a partir de 0,80 de NDVI comprometem a capacidade de demonstrar variabilidade espacial, provocado pelo fenômeno chamado de saturação da banda do vermelho. Isso faz com que se encontrem os valores altos de NDVI e que representam valores de biomassa, N e C com grande amplitude. Esses valores geralmente aparecem nas estimativas quando a cultura do trigo atinge a fase de enchimento de grãos (> 105 DAS).

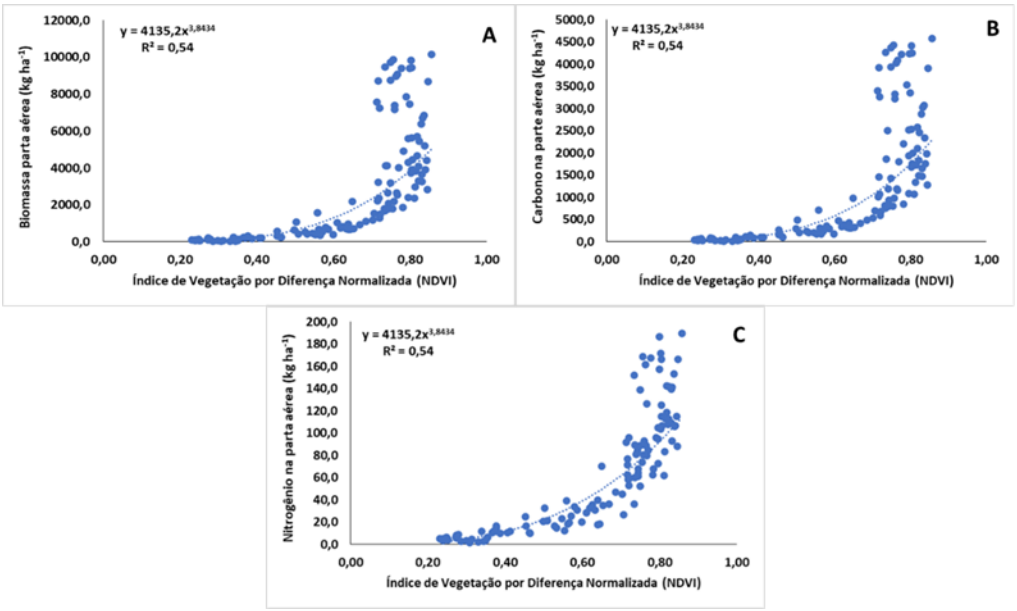


FIGURA 3. Estimativa do acúmulo de biomassa seca na parte aérea (A), de nitrogênio acumulado (B) e de carbono acumulado (C) com base nos valores de Índice de Vegetação por Diferença Normalizada (NDVI), valores. V médios de duas safras agrícolas e das (2018 e 2019) quatro cultivares (BRS Parrudo, BRS Reponte, TBIO Sossego e TBIO Toruk na média dos locais). *modelos exponenciais à 5% de probabilidade.

Com base nas informações anteriores, realizou-se a retirada dos dados considerados "saturados" e que pudessem reduzir a qualidade da estimativa (Figura 4). Os dados retirados da estimativa foram os dados que compreendem os estádios de desenvolvimento do trigo de enchimento de grãos (>105 DAS). Assim, o modelo de estimativa do sequestro de C pela cultura do trigo por meio do NDVI foi construído entre os estádios V3 (formação de afilhos) (>40 DAS) até o florescimento da cultura (100 DAS). Observou-se que a estimativa de acúmulo de C na parte aérea do trigo pela metodologia de NDVI, avaliando entre os estádios V3 até o emborrachamento, observou-se um acúmulo de 2.000 kg de C ha-1. Segundo Veeck et al. (2022), determinaram que durante todo o ciclo produtivo, o trigo (raízes e parte aérea) absorveu um total de 7.540 kg de C ha-1.

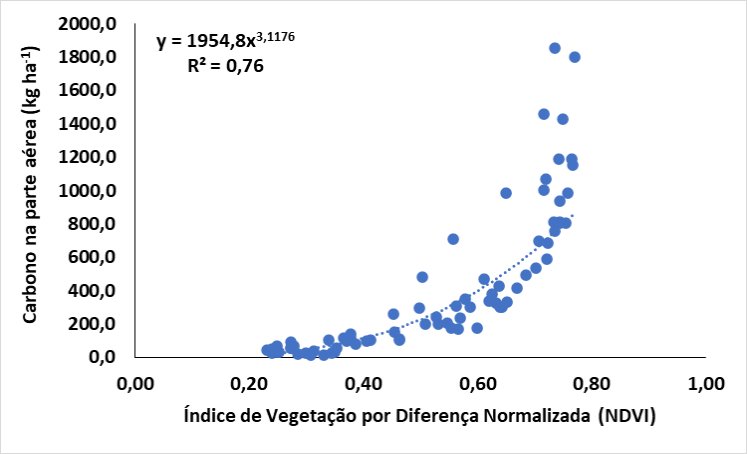


FIGURA 4. Estimativa do acúmulo de carbono na parte aérea do trigo com base nos valores de Índice de Vegetação por Diferença Normalizada (NDVI), valores. V médios corrigidos sem os valores de NDVI saturado para duas safras agrícolas e das (2018 e 2019) quatro cultivares (BRS Parrudo, BRS Reponte, TBIO Sossego e TBIO Toruk na média dos locais). *modelo exponencial à 5% de probabilidade.

CONCLUSÃO

Os resultados da relação C/N dos parâmetros de C e de N demonstraram que quanto maior for a absorção de N, maior é o sequestro de C pelas plantas, ou seja, plantas com adequada nutrição mineral possuem maior capacidade de sequestrar C.

O uso do NDVI mostrou-se uma abordagem eficaz para estimar o sequestro de C a partir da relação entre a absorção de N e o acúmulo de biomassa da cultura do trigo ao longo do seu ciclo de desenvolvimento.

Essa metodologia forneceu um modelo de estimativa do sequestro do C entre os estádios V3 (formação de afilhos) (>30 DAS) até o florescimento da cultura (100 DAS), proporcionando uma representação mais precisa do acúmulo de C na parte aérea do trigo, demonstrando assim, o NDVI como uma ferramenta valiosa para monitorar estas variáveis durante o desenvolvimento da cultura.

REFERÊNCIAS

COMISSÃO DE QUÍMICA E FERTILIDADE DO SOLO (CQFS-RS/SC). Manual de adubação e calagem para os Estados do Rio Grande do Sul e de Santa Catarina. Núcleo Regional Sul, 376p, 2016.

DELOGU G., CATTIVELLI L., PECCHIONI N., FALCIS D.de, MAGGIORE T., STANCA A.M. Uptake and agronomic efficiency of nitrogen in winter barley and winter wheat, European Journal of Agronomy, v. 9, 11-20p, 1998.

EMBRAPA. Informações Técnicas para o Cultivo de Trigo. Brasília: Embrapa-SPI. 1996.

EMBRAPA. Adequate soil management increases carbon sequestration in irrigated areas. Brasília: Embrapa-SPI. 2022. Disponível em: <https://www.embrapa.br/en/busca-de-noticias/-/noticia/72379135/manejo-adequado-do-solo-aumenta-sequestro-de-carbono-em-areas-irrigadas>. Acesso em 06 de abril de 2024.

INMET. Normais Climatológicas. Disponível em: <http://www.inmet.gov.br /portal/index.php?r=clima/normaisClimatologicas>. Acesso em 01 abril de 2024.

IPAGRO. Observações meteorológicas no estado do Rio Grande do Sul. Porto Alegre: IPAGRO, 272p, 1979. (Boletim Técnico, 3).

MANTAI R. D.; SILVA, J.A.G.da.; ARENHARDT, E.G.; SAUSEN, A.T.Z.R.; BINELLO, M.O.; BIANCHI, V.; SILVA, D.R.; BANDEIRA, L.M. The dynamics of relation oat panicle with grain yield by nitrogen. American Journal of Plant Sciences, v.7, 17-27p, 2016.

MARSCHNER, P. Mineral Nutrition of Higher Plants. Academic Press, 2012.

PAULILO, M. T. S., VIANA, A. M., RANDI, A. M. Fisiologia Vegetal. Florianópolis: Universidade Federal de Santa Catarina, 182p, 2015.

REUNIÃO DA COMISSÃO BRASILEIRA DE PESQUISA DE TRIGO E TRITICALE (RCBPTT). Informações técnicas para trigo e triticale - Safra 2017. Brasília: Embrapa, 240p, 2017.

STRECK, E.V.; KAMPF, N.; DALMOLIN, R.C.D. Solos do Rio Grande do Sul. Porto Alegre: EMATER RS, 222p, 2008.

TAIZ, L., ZEIGER, E., MØLLER, I.M., & MURPHY, A. Plant Physiology and Development (6th ed.). Sinauer Associates, 2015.

TEDESCO, M. J, et al. Análise de solo, plantas e outros materiais - 2ª Ed. Porto Alegre: Departamento de Solos da UFRGS, 174p, 1995.

LARGE, E. C. Growth stages in cereals. Plant Pathology, London, v. 3, 128-129p, 1954.

ROUSE, J. W., HAAS, R. H., SCHELL, J. A., & DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. In Third ERTS Symposium, NASA SP-351, Vol. I, 309-317p, 1973. NASA Goddard Space Flight Center.

VEECK G.P., DALMAGO A.G., BREMM T., BULIGON L., JACQUES R.J.S., FERNANDES J.M., SANTI A., VARGAS P.R., ROBERTI D.R. CO2 flux in a wheat-soybean succession in subtropical Brazil: A carbon sink. Journal of Environmental Quality, 2022. Disponível em: <https://acsess.onlinelibrary.wiley.com/doi/10.1002/jeq2.20362>. Acesso em: 6 de abril de 2024.

AVALIAÇÃO TEMPORAL DE LAVOURA DE ALGODÃO PELO ÍNDICE DE VEGETAÇÃO POR DIFERENÇA NORMALIZADA (NDVI)

ALEXANDRE A, PANISSON [1]; ANNA ELISA P. GATELLI [2]; GABRIEL A. ENGEL [2]; TERESA ENDERLE [2]
[1]Mestrando. Bento Gonçalves, 7712. Universidade Federal do Rio grande do Sul; [2]Bolsista. Bento Gonçalves, 7712. Universidade Federal do Rio grande do Sul

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
O algodão é uma cultura agrícola fundamental no Brasil, ocupando a 4ª posição mundial em produção. O acompanhamento técnico é crucial para o sucesso da lavoura, combinando monitoramento presencial e sensoriamento remoto. O NDVI é um índice vital nesse processo, indicando o desenvolvimento da cultura com base na reflectância de infravermelho próximo e vermelho da luz por meio de imagens de satélite. O objetivo do estudo foi avaliar como o manejo e clima poderiam influenciar na variação de NDVI encontrada durante o desenvolvimento completo de uma lavoura de algodão. Este estudo acompanhou o ciclo do algodoeiro em uma área de Costa Rica (MS) durante a safra 2022/2023, utilizando imagens de satélite do Sentinel 2 via Auravant®. Apesar dos desafios de qualidade de imagem devido à interferência de nuvens pela pluviosidade, o NDVI mostrou variações significativas ao longo do ciclo, correlacionando-se com os estágios fenológicos da cultura. A produtividade real da lavoura superou as expectativas, evidenciando a importância do monitoramento do NDVI para otimização da produção. Este estudo ressalta tanto a utilidade quanto as limitações práticas do NDVI como ferramenta de gestão agrícola.

PALAVRAS-CHAVE: *Gossypium hirsutum* L; Sensoriamento remoto; Tecnologias agrícolas

ABSTRACT
Cotton is a fundamental agricultural crop in Brazil, ranking 4th in the world in production. Technical monitoring is crucial for the success of the crop, combining on-site monitoring and remote sensing. The NDVI (Normalized Difference Vegetation Index) is a vital index in this process, indicating crop development based on the reflectance of near-infrared and red light through satellite images. The objective of the study was to evaluate how management and climate could influence the variation of NDVI observed during the complete development of a cotton crop. This study tracked the cotton cycle in an area of Costa Rica (MS) during the 2022/2023 season, using Sentinel-2 satellite images via Auravant®. Despite challenges in image quality due to cloud interference from rainfall, the NDVI showed significant variations throughout the cycle, correlating with the phenological stages of the crop. The actual productivity of the crop exceeded expectations, highlighting the importance of NDVI monitoring for optimizing production. This study underscores both the usefulness and practical limitations of NDVI as an agricultural management tool.

KEYWORDS: ;;

INTRODUÇÃO

O algodão (Gossypium hirsutum L.) é uma das principais culturas agrícolas cultivadas no Brasil que atualmente ocupa a 4ª posição em volume produzido mundialmente (FAO, 2023). A produção nacional foi estimada em 3,27 milhões de toneladas de plumas na safra 2022/2023, sendo Mato Grosso o estado responsável por aproximadamente 65% desse volume (CONAB, 2023). É notória a importância econômica do algodoeiro para o agronegócio brasileiro que apresenta relevante participação no produto interno bruto do país. Por isso é imprescindível que as tecnologias utilizadas

nos sistemas produtivos sejam efetivas e inovadoras para a manutenção e progressão das altas produtividades obtidas em seu cultivo (MONTES et al., 2019).

Um dos fatores que determinam o sucesso de uma lavoura é o acompanhamento técnico para a determinação dos manejos que serão empregados. Ainda, o monitoramento presencial da lavoura é necessário independentemente do uso de sensoriamento remoto, pois possibilita compreender o contexto do ambiente e as atuações mais discretas de solo, clima e agentes bióticos sobre as plantas. Neste sentido, as imagens aéreas demonstram grande utilidade em diversos tipos de análises que contribuem com o processo da tomada de decisão dentro das propriedades (SHIRATSUCHI et al., 2014).

O sensoriamento remoto por meio de imagens de satélites permite avaliar o desenvolvimento da lavoura durante todo seu ciclo (SILVA & SILVA-MANN, 2020). E de forma complementar às avaliações presenciais, as imagens fornecem informações de crescimento e status nutricionais da cultura, que por meio de índices de vegetação, permite que a produção vegetal pode ser avaliada (AMMONIACI et al., 2021). O Índice de Vegetação por Diferença Normalizada (NDVI) é um índice de vegetação comumente utilizado para avaliar o desenvolvimento das lavouras a partir de imagens de satélite feita por câmeras acopladas. Ele é calculado a partir da diferença entre a reflectância do infravermelho próximo e do vermelho da luz e valores próximos de +1 indicam vegetação densa e saudável (ROUSE et al., 1973). Durante o ciclo de crescimento das plantas, o NDVI oferece insights sobre a saúde, vigor e desenvolvimento das culturas, permitindo aos agricultores identificar problemas como estresse hídrico, deficiências nutricionais ou infestações de pragas. Essa informação ajuda na tomada de decisões, como a aplicação precisa de insumos agrícolas, tornando a gestão das lavouras mais eficiente e sustentável.

OBJETIVOS

O objetivo do estudo foi desenvolver a curva espectral do índice de vegetação por diferença normalizada da cultura do algodão ao longo de seu ciclo de desenvolvimento vegetativo e reprodutivo.

MATERIAL E MÉTODOS

O estudo foi realizado na safra de 2022/2023 em uma área de 168,56 ha, localizada no munícipio de Costa Rica (MS). O clima da região é caracterizado como tropical de monção, Aw segundo Koppen, com temperatura média do mês mais frio superior a 18ºC e estação seca de pequena duração (ALVARES et al., 2013; IVASKO JÚNIOR et al., 2020). O solo da área é classificado como Latossolo Vermelho Distrófico (FACCIN, 2018) de classe textural muito argilosa e argilosa.

Os valores de NDVI foram obtidos pela plataforma Auravant®, que utiliza imagens de satélite provenientes do Sentinel 2, com resolução espacial de 10 x 10 metros e com resolução temporal entre 4 a 10 dias, contanto que não haja presença de nuvens (AURAVANT, 2023).

Para caracterizar os atributos químicos e físicos do solo, buscou-se os dados da amostragem e análise de solo realizados anteriormente à instalação da cultura a campo, sendo os resultados apresentados no Quadro 1.

QUADRO 1. Valores de diversos parâmetros da análise de solo anterior ao plantio.

Ano	pH	H+Al	Al	Ca	Mg	K	P-mehlich	P-resina	S	MO	V	Soma de Bases	CTC
	CaCl2		cmolc/dm³				mg/dm³			%		cmolc/dm³	

2022	5,2	4	0,03	3,9	1,7	0,3	5,4	25	12,5	2,95	60	5,89	9,89	

A semeadura do algodão foi realizada entre os dias 08 e 09 de dezembro de 2022 e a colheita, nos dias 29 e 30 de julho de 2023. A variedade utilizada foi a FM 944 GL, reconhecida pela qualidade de fibra e potencial produtivo, com ciclo de maturação de 180 dias, tecnologia GlyTol®, LibertyLink® e resistência à virose (doença azul) (BASF). A população final de plantas foi de 95.000 plantas/ha. A produtividade obtida foi de 403 @/ha. O manejo da calagem para correção do solo foi realizado em 29 de julho de 2022 com a aplicação de 2,5 t/ha de calcário dolomítico. Os dados de precipitação foram obtidos a partir de leituras diárias de uma estação pluviométrica automática do INMET instalada na cidade de Costa Rica - MS durante o período de 01 de dezembro de 2022 a 30 de julho de 2023. A precipitação total durante este período foi de 1.450,6 mm (Figura 1).

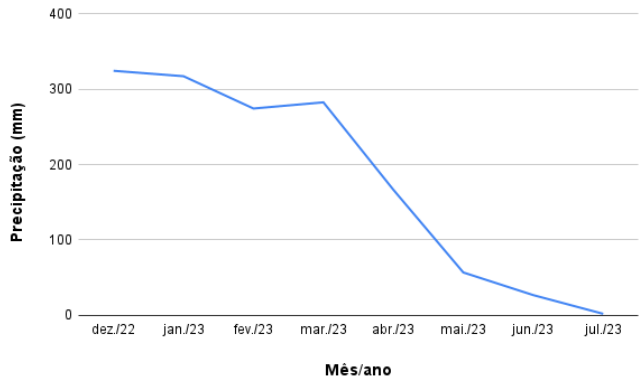


FIGURA 1. Valores de precipitação do período estudado.

RESULTADOS E DISCUSSÃO

Ao longo do ciclo de desenvolvimento da cultura do algodão foram analisadas 19 imagens úteis de um total de 49 imagens registradas ao longo da safra, pela plataforma Auravant®. Os dados revelaram uma baixa disponibilidade de imagens de satélite entre dezembro de 2022 e abril de 2023 principalmente, destacando a interferência de nuvens na captação dessas imagens. Essa escassez de dados pode ser diretamente atribuída à elevada incidência de dias chuvosos, conforme evidenciado pela Figura 2, em que a porcentagem de dias com precipitação excedendo 1 mm variou de 64,52% em dezembro de 2022 a 43,33% em abril de 2023. A avaliação dos níveis de NDVI durante o ciclo do algodoeiro foram agrupados na Figura 2.

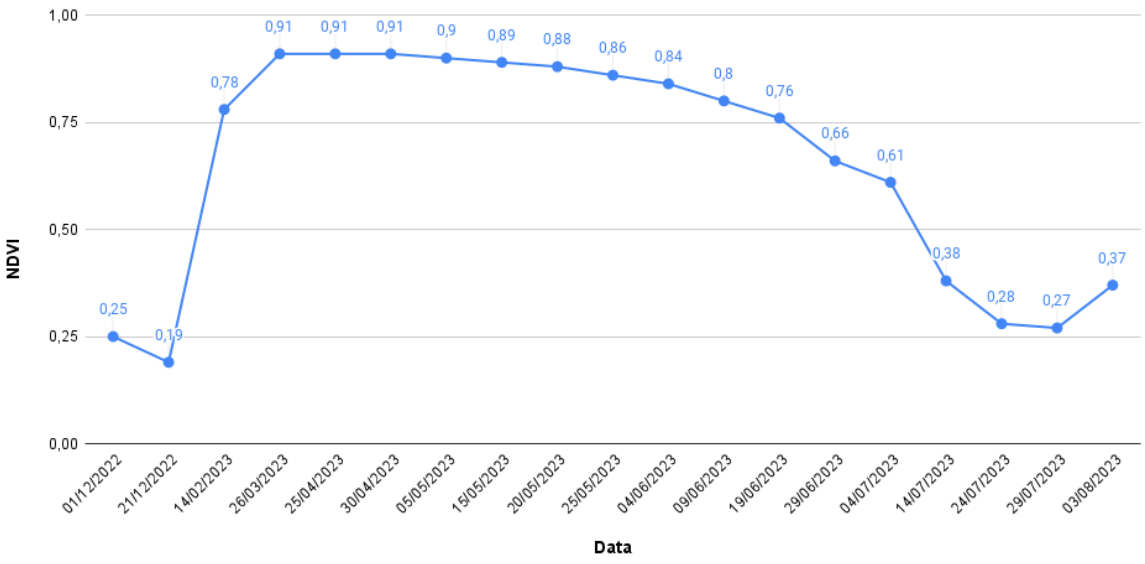


FIGURA 2. Valores de NDVI do período estudado.

Das 19 imagens com dados espectrais disponíveis, 12 foram utilizadas para demonstrar os resultados de NDVI obtidos (Figura 3). A supressão das imagens entre 25 de abril de 2023 e 04 de junho de 2023 foi definida por não demonstrarem mudanças significativas pela saturação do NDVI. As imagens selecionadas foram coletadas de 01/12/2022 a 03/08/2023, sendo que a primeira e a última imagens são datadas de antes do plantio e após a colheita da cultura, respectivamente.

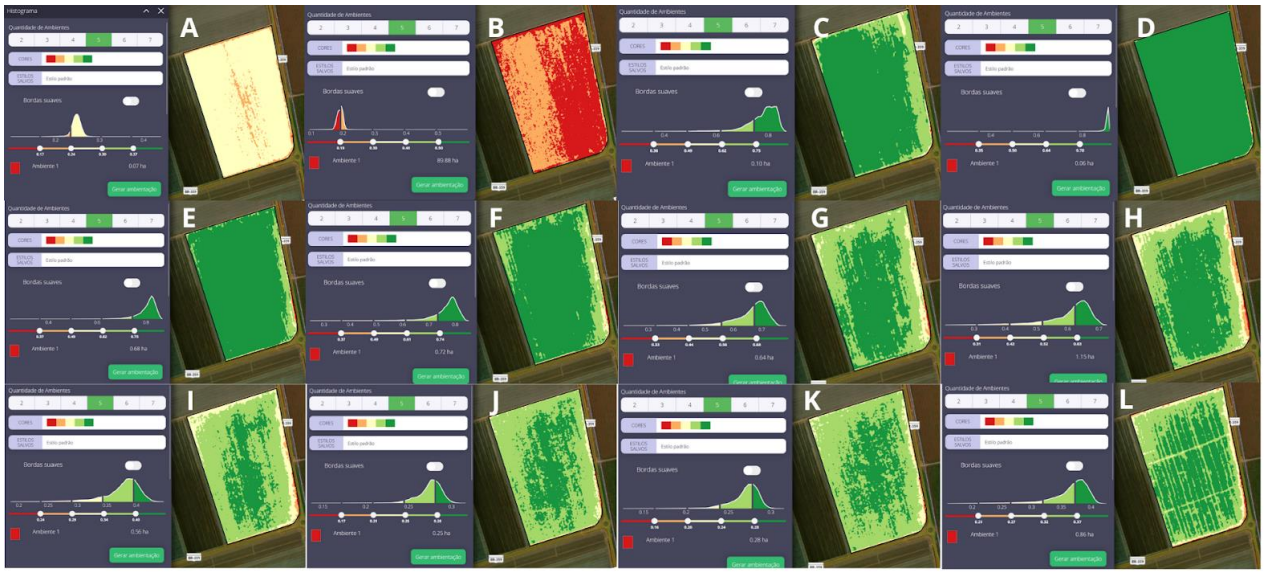


FIGURA 3. Imagens de NDVI da área com respectiva escala, datadas de (A) 01 de Dezembro/22, (B) 21 de Dezembro/22, (C)14 de Fevereiro/23, (D) 26 de Março/23, (E) 09 de Junho/23, (F) 19 de Junho/23, (G) 29 de Junho/23, (H) 04 de Julho/23, (I) 14 de Julho/23, (J) 24 de Julho/23, (K) 29 de Julho/23, (L) 03 de Agosto/23.

Destaca-se que a presença de nuvens prejudicou a qualidade das imagens, comprometendo a precisão das leituras, especialmente relacionadas ao NDVI. A abundância de chuva, portanto, impactou

negativamente a qualidade das imagens capturadas, resultando em uma falta de informações cruciais para a análise adequada das condições agrícolas no período em questão.

A progressão temporal do NDVI do algodoeiro durante seu ciclo fenológico permitiu que entender o comportamento do crescimento e desenvolvimento do algodoeiro, bem como a capacidade fotossintética da cultura. Estudos evidenciaram uma forte associação entre o NDVI e outras variáveis da cultura, como a área foliar (BEZERRA; FIDELIS FILHO, 2009) e o coeficiente de cultura (HUNSAKER et al., 2003, HUNSAKER et al., 2007; LÓPEZ-URREA et al., 2009). Bezerra et al. (2012), examinaram a evolução temporal do NDVI do algodoeiro ao longo de seu ciclo fenológico, utilizando uma curva que ilustra o desenvolvimento da planta.

Os valores de NDVI entre as datas 01/12/22 e 21/12/22 foram atribuídos à presença de plantas espontâneas antes do plantio do algodão e a subsequente aplicação de herbicidas em 14/12/22. A possibilidade de cobertura por vegetação espontânea em 01/12/22 pode ter influenciado os valores de NDVI. Após a aplicação dos herbicidas, houve a supressão dessas plantas, resultando em uma redução da vegetação verde e, consequentemente, em um NDVI ainda mais baixo em 21/12/22. É importante destacar que o algodão tenha sido semeado em 09/12/22, fatores ambientais como disponibilidade de água, temperatura e condições do solo podem ter afetado seu desenvolvimento, o que contribuiu para a redução do NDVI em estágios iniciais de crescimento, como observado após 18 dias da semeadura. Esta interpretação ressalta a importância de considerar diversos fatores ambientais e práticas agrícolas na análise do NDVI como indicador do estado da vegetação em estudos agronômicos.

No período de 0 a 70 DAS aproximadamente, ocorreu um aumento gradual dos valores do NDVI, atingindo valores superiores a 0,85 (figura 3). Isso corresponde ao estágio de desenvolvimento vegetativo da cultura, potencializado pelas adubações iniciais, caracterizado pelo aumento da área foliar até cobrir completamente o solo. Dos 70 aos 120 DAS aproximadamente, o NDVI manteve-se praticamente constante, ligeiramente acima de 0,80, saturado. Esses valores estão em concordância com estudos anteriores (HUNSAKER et al., 2003; BEZERRA; FIDELIS FILHO, 2009) e são típicos do estágio reprodutivo ou médio da cultura, que vai da floração ao início da maturação. Durante esse período, os valores do NDVI permanecem estáveis devido à estabilização da área foliar, já que o NDVI é influenciado pela refletância multiespectral, sensível ao índice de área foliar e/ou à fração de cobertura do solo (CHOUDHURY et al., 1994).

Por fim, a produtividade real da lavoura superou em 73,25@ a produtividade planejada que era de 330@/ha. Para fins comparativos, a expectativa média do estado na safra 2022/2023 era de 300@/ha de acordo com a Fundação MT (2023) e a lavoura acompanhada atingiu 403,25@/ha. Em geral, a safra foi marcada por condições climáticas favoráveis à cultura. Isto, somado aos manejos realizados de forma planejada e proporcional às necessidades da plantação, resultou em uma produtividade que superou as expectativas iniciais.

CONCLUSÃO

Com base nos resultados obtidos o monitoramento do NDVI durante o ciclo do algodoeiro acompanhou o desenvolvimento da cultura demonstrando aumento dos valores do índice desde a emergência com uma rápida saturação e redução gradual conforme a evolução dos estádios reprodutivos. Os mapeamentos realizados enfrentaram desafios relacionados à alta pluviosidade que, por meio da interferência das nuvens, influenciou negativamente a qualidade e a disponibilidade das imagens de satélite. Por fim, esses dados foram utilizados na avaliação do desenvolvimento do algodoeiro, impactando no aumento da eficiência na produção da cultura.

REFERÊNCIAS

ALVARES, C. A. et al. Mapa de classificação climática de Köppen para o Brasil. Meteorologische Zeitschrift, v. 22, n. 6, p. 711-728, 2013.

AMMONIACI, M.; KARTSIOTIS, S-P.; PERRIA, R.; STORCHI, P. "Estado da Arte das Tecnologias de Monitoramento e Processamento de Dados para Viticultura de Precisão". Agricultura, v. 11, n. 3, p. 201, 2021. https://doi.org/10.3390/agriculture11030201

AURAVANT. Origem, resolução e frequência de imagens de satélite. Disponível em: https://www.auravant.com/pt/ajuda-pt/imagens-e-camadas/3636671-origem-resolucao-e-frequencia-de-imagens-de-satelite/. Acesso em: 02 fev. 2024.

BASF. FiberMax: Proteção de Cultivos e Sementes. Disponível em: https://agriculture.basf.com/br/pt/protecao-de-cultivos-e-sementes/produtos/fibermax.html#text-1954371869. Acesso em: 02 fev. 2024.

BEZERRA, B. G. et al. Evapotranspiração e coeficiente de cultura do algodoeiro irrigado a partir de imagens de sensores orbitais. Revista Ciência Agronômica, v. 43, n. 1, p. 64-71, 2012.

BEZERRA, B. G.; FIDELES FILHO, J. Análise de crescimento da cultura do algodoeiro irrigada com águas residuárias. Revista Ciência Agronômica, v. 40, n. 3, p. 339-345, 2009.

CHOUDHURY, B. J. et al. Relations between evaporation coefficients and vegetation indices studies by model simulations. Remote Sensing of Environment, v. 50, p. 1-17, 1994.

Companhia Nacional de Abastecimento (Conab). Levantamento Sistemático da Produção Agrícola (LSPA). Brasília, DF: Conab, 2023.

FACCIN, A. C. T. M. O complexo soja e o quadro natural de Mato Grosso do Sul: características naturais e centralidade do cultivo. Geoambiente On-line, n. 31, 2018.

FAO. Anuário Estatístico da FAO. Roma: FAO, 2023

FUNDAÇÃO MT. Safra de algodão 2022/23 de MT pode ter recorde histórico de produtividade. Disponível em: https://www.fundacaomt.com.br/noticias/safra-de-algodao-202223-de-mt-pode-ter-recorde-historico-de-produtividade-50fd. Acesso em: 02 fev. 2024.

HUNSAKER, D. J. et al. Estimating cotton evapotranspiration crop coefficients with a multispectral vegetation index. Irrigation Science, v. 22, n. 2, p. 95-104, 2003.

IVASKO JÚNIOR, S. et al. Classificação do estado de Mato Grosso do Sul segundo sistema de zonas de vida de Holdridge. Revista Brasileira de Climatologia, v. 26, 2020.

LÓPEZ-URREA, R. et al. Water use of spring wheat to rise water productivity. Agricultural Water Management, v. 96, n. 9, p. 1305-1310, 2009.

MONTES, G. C.; GODOY, C. V.; FERREIRA, M. A. Importância Econômica da Cultura do Algodão no Brasil. Embrapa Algodão, 2019.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. In: Third ERTS Symposium, NASA SP-351 (Vol. I, pp. 309-317). NASA Goddard Space Flight Center, 1973.

SHIRATSUCHI, L. S. et al. Sensoriamento Remoto: conceitos básicos e aplicações na Agricultura de Precisão. In: Bernardi, ACC; Naime, JM; Resende, AV; Bassoi, LH (Eds.). 2014.

SILVA, W. V. R.; SILVA-MANN, R. Agricultura de Precisão no Brasil: conjuntura atual, desafios e perspectivas. Research, Society and Development, v. 9, n. 11, e1979119603, 2020. https://doi.org/10.33448/rsd-v9i11.9603

IMAGEM DE FLUORESCÊNCIA NA DETECÇÃO PRECOCE DE ESTRESSE BIÓTICO NO ALGODÃO

OTAVIO RODRIGUES DE PAULA [1]; BIANCA BATISTA BARRETO [2]; LETÍCIA PIAZENTIN DANTAS [1]; JOÃO VICTOR SILVA VIANA [1]; DÉBORA MARCONDES BASTOS MILORI [3]

[1]Estágio. Rua XV de novembro, 1452 - Centro, São Carlos - SP. Empresa Brasileira de Pesquisa Agropecuária; [2]Pós doutorado. Rua XV de novembro, 1452 - Centro, São Carlos - SP. Empresa Brasileira de Pesquisa Agropecuária; [3]Pesquisador . Rua XV de novembro, 1452 - Centro, São Carlos - SP. Empresa Brasileira de Pesquisa Agropecuária

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

O setor da cotonicultura no Brasil se destaca mundialmente e coloca o país em uma posição consolidada nesse mercado como um grande produtor e exportador de derivados do algodão. Neste cenário, a preocupação com a incidência e o surgimento de novas doenças cresce igualmente. Entre os patógenos que atacam o algodoeiro, o nematoide Aphelenchoides besseyi, têm sido alvo frequente de dessossego por parte dos produtores, por causar perdas de produtividade e, consequentemente, econômicas. A besseyi, é o agente etiológico da "Soja Louca II", que afeta as culturas brasileiras de soja, sabidamente, desde 2015 e, no ano de 2018, foi confirmado como causador de doença também no algodoeiro. Entre os principais sintomas causados pelo ataque ao algodoeiro estão o enrugamento de folhas, a abscisão de botões florais e o estiolamento da planta. A análise da dinâmica da fluorescência das plantas oferece informações valiosas a respeito da situação fisiológica em que se encontram e permite identificar possíveis fontes de estresse. Nesse sentido, o objetivo deste trabalho foi a aplicação de sistemas de imagem de fluorescência induzida por LED para detectar precocemente o estresse biótico causado por A. besseyi, em algodoeiros cultivados em casa de vegetação, sob condições ambientais controladas. Os dados extraídos das imagens de fluorescência foram submetidos a um algoritmo de classificação baseado em aprendizado de máquina que atingiu 70% de taxa de acerto para o grupo de teste na fase assintomática e 100% na fase sintomática inicial. Os resultados obtidos mostraram que a detecção precoce do patógeno a partir de imagens de fluorescência é uma abordagem promissora no monitoramento das culturas de algodão, no que diz respeito ao ataque por A. besseyi.

PALAVRAS-CHAVE: Imagem de fluorescência; Algodão; Estresse biótico

ABSTRACT

The cotton sector in Brazil stands out worldwide and places the country in a consolidated position in the market as a major producer and exporter of cotton derivatives. In this scenario, concern about the incidence and emergence of new diseases is also growing. Among the pathogens that attack cotton, the nematode Aphelenchoides besseyi has been a frequent target of destruction by producers, as it causes productivity and, consequently, economic losses. A. besseyi is the etiological agent of "Soja Louca II", which has been known to affect Brazilian soybean crops since 2015 and, in 2018, was confirmed as causing disease also in cotton. Among the main symptoms caused by the attack on cotton plants are the wrinkling of leaves, the abscission of flower buds and the etiolation of the plant. An analysis of the dynamics of plant fluorescence offers useful information regarding the physiological situation in which they find themselves and allows the identification of possible sources of stress. In this sense, the objective of this work was the application of LED fluorescence imaging systems to early detect biotic stress caused by A. besseyi, in cotton plants grown in a greenhouse, under controlled environmental conditions. The data extracted from the fluorescence images were subjected to a machine learning-based classification algorithm that achieved a 70% hit rate for the

test group in the asymptomatic phase and 100% in the initial symptomatic phase. The results demonstrated that the early detection of the pathogen from fluorescence images is a promising approach in monitoring cotton crops, with regard to attack by A. besseyi.

KEYWORDS: ;

INTRODUÇÃO

O Brasil tem grande destaque na produção do algodão e seu posicionamento nesse mercado tem se consolidado a cada ano. Hoje, o país ocupa o quarto lugar no ranking dos maiores produtores e o segundo entre os maiores exportadores de fibra de algodão no mundo. Na safra de 2023/2024, a estimativa é de que o país produza cerca 3,64 milhões de toneladas de pluma de algodão (CONAB, 2024). Seguido do aumento da produtividade e da área de plantio da cotonicultura brasileira, houve também uma crescente incidência e surgimento de novas doenças nas culturas de algodão nas últimas décadas. A "soja Louca II", doença conhecida por causar prejuízos significativos à sojicultura desde o ano de 2005, tem como agente etiológico o nematoide *Aphelenchoides besseyi*, identificado em 2015 como o causador de tal doença. Em 2018, foi confirmado o primeiro relato do nematoide *A. besseyi* causando doença no algodoeiro. Desde então, este patógeno se destaca por ocasionar baixos rendimentos e prejuízos econômicos ao produtor, devido à inexistência de defensivos e estratégias de manejo eficazes (MEYER et al. 2017). A partir do estabelecimento de novos conceitos da agricultura de precisão e das ferramentas que a era digital proporciona, como maior conectividade e capacidade de integração de sensores e dados, novas demandas têm surgido no âmbito do desenvolvimento de novos dispositivos, métodos, protocolos e sistemas integráveis (BASSOI et al., 2019). Devido à complexidade atual envolvida na produção agropecuária, que une aspectos biológicos, ambientais e socioeconômicos, a automação de métodos e sistemas de monitoramento por meio de técnicas fotônicas tem se mostrado uma abordagem com enorme oportunidade de avanço. Uma possibilidade é a detecção precoce de estresses causados por patógenos nas plantas através da utilização de técnicas fotônicas (Chaerle & Van Der Straeten, 2000; Pérez Bueno et al., 2016). A fotônica é um ramo da física que estuda aplicações da geração, manipulação e detecção da luz. Frequentemente, as técnicas fotônicas envolvem o uso de lasers e são largamente aplicadas em várias áreas por sua sensibilidade, precisão e alto potencial de portabilidade (Cardinali, et al., 2012). Dada a importância e a contribuição socioeconômica desse setor e a inexistência de métodos de detecção eficazes e logisticamente viáveis, a busca por alternativas que ajudem no combate a esse patógeno torna-se um problema emergente. O uso de sistemas de imagem de fluorescência induzida por LED tem se mostrado capaz de fornecer informações de extrema relevância sobre a cinética da fluorescência da planta e, consequentemente, a respeito também da eficiência fotossintética, dada a proporcionalidade desses processos (CHAERLE, et al., 2007). Portanto, o objetivo deste trabalho foi, através da aplicação de sistemas de imagem de fluorescência induzida por LED, identificar precocemente o estresse causado por *A. besseyi* em algodoeiros cultivados em casa de vegetação.

OBJETIVOS

O objetivo deste trabalho foi a detecção precoce do estresse causado por *A. besseyi* em algodoeiros cultivados em casa de vegetação a partir do uso de sistemas de imagem de fluorescência induzida por LED.

MATERIAL E MÉTODOS

As amostras de algodão foram cultivadas em casa de vegetação sob condições controladas de temperatura (30°C) e umidade relativa (80%). As sementes utilizadas foram do cultivar IMA5801B2RF, Campo 2OP, Safra 2019/20, cedidas pelo Instituto Mato-grossense do Algodão/IMA. A inoculação dos nematoides foi realizada nove dias após a semeadura e o

monitoramento com o sistema de fluorescência, dois dias após a inoculação. A inoculação dos nematoides foi feita a partir do gotejamento de solução aquosa com o auxílio de micropipetas de precisão, em uma densidade próxima de 500 nematoides por planta, (Figura 1).



FIGURA 1. Inoculação da planta com patógeno junto à base do caule da planta.

O monitoramento foi realizado em um período de 21 dias, totalizando dez tempos. As medições foram sempre nos mesmos horários e na mesma sequência. Foram utilizados oito vasos testemunhas e oito vasos inoculados por tempo, totalizando 160 amostras. As medidas com o sistema de imagem de fluorescência foram realizadas respeitando um período de 30 minutos em que as amostras permaneceram no escuro para a inativação da atividade fotossintética. Para a medição da fluorescência foi utilizado o equipamento Closed FluorCam FC 800-C da Photon System Instruments e adotado um dos protocolos que acompanham o equipamento "Actinic Light Curve II" e que permite a avaliação da cinética da fluorescência e, consequentemente, da dinâmica da fotossíntese de forma não invasiva. O FluorCam é um fluorômetro que comporta a planta em seu interior e pode ser fechado para impedir que fontes de excitação externas influenciem na aquisição das imagens. O equipamento é equipado com uma câmera CCD, painéis de LED fixos, cinco tipos de filtros passa-banda e acompanhado do software FluorCam 7, que permite a operação do equipamento, ajustes de parâmetros e processamentos das imagens obtidas. Neste protocolo foi utilizado o filtro da clorofila (ChlF) e a imagem da dinâmica da fluorescência. Os parâmetros ajustáveis foram: i) Shutter, tempo de abertura da câmera, equivalente a (1) 20 us; ii) Flashes, ajuste da sensibilidade, buscando manter a cor da escala da amostra em 500, relativo ao azul escuro na escala de cores; iii) Act 2, ajuste da intensidade, buscando manter a cor da amostra na escala entre 1.000 e 1.500, relativo ao verde na escala de cores; iv) Super, pulso de saturação, buscando manter a imagem da amostra branca. A intensidade da luz actinic varia de 300-2.000 μmol. m -2 . s -1 e a intensidade do super pulso vai até 4.000 μmol. m -2 . s -1, com a variação de acordo com o ajuste dos parâmetros para cada amostra. Como as amostras diferiram umas das outras em altura, tamanho e geometria, permitiu-se um ajuste destes parâmetros para cada amostra. Com todos os parâmetros ajustados, foi realizada a aquisição dos dados. Ao utilizar o protocolo Actinic Light Curve II, primeiramente foi medida a emissão de fluorescência mínima (F0) e a emissão de fluorescência máxima (FM). Para esta aquisição, a sequência pré-determinada das luzes de LED se repetem por seis vezes e, durante este processo, ocorre a medição dos parâmetros. O protocolo dinâmico compreende 80 parâmetros. E entre esses, alguns são mensurados e outros são calculados. Para a obtenção dos resultados e confecção de planilhas, foi selecionada a região de interesse na imagem obtida, referente a cada amostra em análise, contendo apenas a parte aérea das mesmas (Figura 2). A partir das imagens obtidas e as áreas delimitadas, os resultados foram processados no programa FluorCam 7.0, e os parâmetros relativos ao protocolo, determinados.

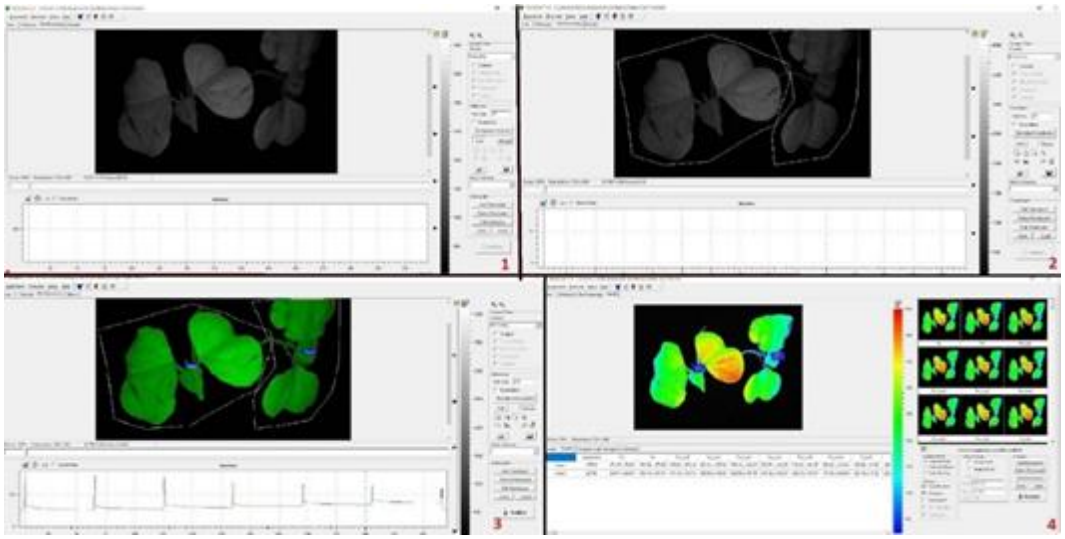


FIGURA 2. Delimitação das áreas de interesse e cálculo dos parâmetros no programa FluoCam 7.0

Com o protocolo Actinit Light Curve - II, foram obtidos 80 parâmetros por planta, extraídos pelo programa, a partir das imagens geradas pelo equipamento. Para cada um dos parâmetros, o programa forneceu a média e desvio padrão da imagem de cada planta que foram extraídos e tabelados e, posteriormente, analisados a partir da implementação de um algoritmo de classificação baseado em aprendizado de máquina. Todo o processamento dos dados e implementação do modelo foram realizados em Python, com as bibliotecas numpy e pandas, para a manipulação e visualização dos dados, e a biblioteca SKlearn para o processamento dos dados e implementação do modelo de classificação baseado em análise discriminante. O Google Colab foi adotado como editor principal para a implementação do algoritmo. Os modelos foram gerados por tempo após a inoculação, separadas em fase assintomática e sintomática inicial. A fase assintomática, ainda foi dividida em semana I e semana II.

RESULTADOS E DISCUSSÃO

A dinâmica da fluorescência foi medida com o protocolo Light Curve 2 pré-estabelecido pelo equipamento utilizado. Para este protocolo são medidos aproximadamente 80 parâmetros da fluorescência entre os centros de reações da planta totalmente abertos para os centros totalmente fechados. Para as imagens da dinâmica da fluorescência os resultados do conjunto de teste foram de 69% de taxa de acerto para Fase Assintomática Semana I, classificando incorretamente apenas três sadias como inoculadas e duas inoculadas como sadias; para a Fase Assintomática Semana II, a classificação foi de 69% de taxa de acerto, classificando incorretamente apenas duas sadias como inoculadas e três inoculadas como sadias; e, Fase sintomática Inicial, a classificação foi 100% de taxa de acerto. Assim, as imagens da dinâmica da fluorescência mostraram-se sensível o bastante para classificar corretamente todas as amostras da Fase Assintomática Inicial. A Figura 3 mostra a matriz de média das classes testemunha (azul) e inoculada (laranja) e a matriz de confusão com os respectivos valores da taxa de acerto para cada modelo desenvolvido para os tempos após a inoculação para simulação noturna.

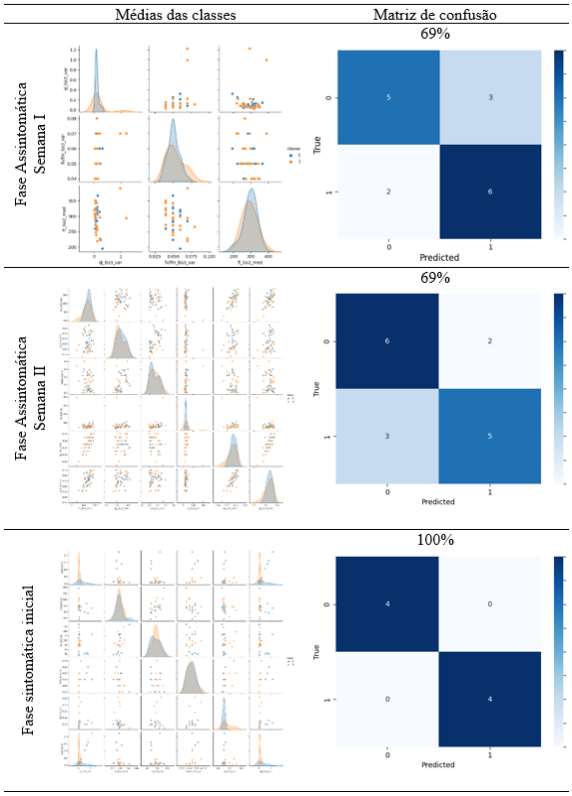


FIGURA 3. Histogramas das médias dos parâmetros e Matrizes de confusão separados em fase assintomática e sintomática.

CONCLUSÃO

Conclui-se que o uso de sistemas de imagem de fluorescência é promissor na detecção precoce de *A. besseiy* em culturas de algodão e que o modelo de classificação baseado em análise discriminante se destacou em comparação com outros comumente utilizados no contexto do aprendizado de máquina. A metodologia aqui proposta apresenta ainda um grande potencial de aprimoramento tanto na etapa de coleta de dados, a partir de otimizações na inoculação dos nematoides e aquisição de imagens, quanto no tratamento e exploração dos dados visando taxas de acerto maiores que viabilizem e estimulem testes em campo.

AGRADECIMENTOS

Este trabalho foi financiado por Embrapa instrumentação, CAPES, FAPESP, CNPq, COMDEAGRO e IMA.

REFERÊNCIAS

BASSOI, L. H. et. al. Agricultura de precisão e agricultura digital. **TECCOGS - Revista Digital de Tecnologias Cognitivas**, n. 20, p. 17-36, 2019.

CARDINALI, M.C.D.B., VILLAS BOAS, P.R., MILORI, D.M.B.P., FERREIRA, E.J., FRANÇA E SILVA, M., MACHADO, M.A., BELLETE, B.S. & DA SILVA, M.F.D.G.F. Infrared spectroscopy: a potential tool in huanglongbing and citrus variegated chlorosis diagnosis. **Talanta**, v. 91, p.1-6, 2012.

CHAERLE, L. et al. Monitoring and screening plant populations with combined thermal and

chlorophyll fluorescence imaging. **Journal of Experimental Botany**, v. 58, n. 4, p. 773-784, (2007).

CHAERLE, L.; VAN DER STRAETEN, D. Imaging techniques and the early detection of plant stress. **Trends in Plant Science**, v. 5, p.495-501, 2000.

CONAB. COMPANHIA NACIONAL DE ABASTECIMENTO. **Acompanhamento de safra brasileiro - grãos**: Oitavo levantamento, maio 2024 - safra 2023/2024. : Brasília: Companhia Nacional de Abastecimento. 2024. Disponível em:<https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos>. Acesso em: 16 mai. 2024.

MEYER, M. C.; FAVORETO, L.; KLEPKER, D.; MARCELINO-GUIMARÃES, F. C. Soybean green stem and foliar retention syndrome caused by Aphelenchoides besseyi. **Tropical Plant Pathology**, v. 42, n. 5, p. 403-409, 2017.

PÉREZ-BUENO, M. L. et al. Multicolor fluorescence imaging as a candidate for disease detection in plant phenotyping. **Frontiers in plant science**, v. 7, p. 225875, 2016.

MAPEAMENTO DA ALTURA DE CAFEEIROS POR MEIO DO SENSOR LIDAR EMBARCADO EM AERONAVE REMOTAMENTE PILOTADA EM LAVOURA ATINGIDA POR GEADA

AMARA LANA DE ABREU [1]; GABRIEL ARAÚJO E SILVA FERRAZ [2]; ROSALRA MARIA ALVES DE MORAIS [1]; ARTHUR CORREA DE NORONHA [1]; RAFAEL DE OLIVEIRA FARIA [2]

[1]Bolsista. Trevo Rotatório Professor Edmir Sá Santos Universidade Federal de, Lavras - MG, 37203-202. UNIVERSIDADE FEDERAL DE LAVRAS ; [2]Docente. Trevo Rotatório Professor Edmir Sá Santos Universidade Federal de, Lavras - MG, 37203-202. UNIVERSIDADE FEDERAL DE LAVRAS

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Técnicas e tecnologias de agricultura de precisão aperfeiçoam os recursos utilizados pelo produtor, proporcionando eficiencia nas suas atividades na lavoura, dentre eles o mapeamento de atributos ganha relevante destaque. Nexte contexto, o objetivo do presente trabalho foi mapear a altura dos cafeeiros de uma lavoura atingida por geada. Para tal, o presente experimento foi conduzido na zona rural da cidade de Santo Antônio do Amparo, na fazenda Bom Jardim, em uma lavoura cafeeira (*Cofea arabica* L.) da cultivar Catucaí vermelho IAC 144 em uma área de 3.5ha. Nesta área foi realizado um voo com uma aeronave remotamente pilotada (*Remotely Piloted Aircraft* - RPA) embarcada com um sensor LiDAR (Zemuse L1). Os dados foram analisados e o mapeamento da altura de planta da área foram realizados em softwares de geoprocessamento. Como resultados obteve-se o mapeamento da lavoura identificando a variabilidade espacial da altura dos cafeeiros, sendo, portanto, possível identificar os locais onde as alturas das plantas apresentavam menores valores, sendo locais mais acometidos pela geada e locais onde as plantas apresentaram maiores valores de altura, sendo portanto, menos afetados pelo evento geada.

PALAVRAS-CHAVE: Laser scanner; cafeicultura; drone

ABSTRACT

Precision agriculture techniques and technologies improve the resources used by the producer, providing efficiency in their farming activities, among which the mapping of attributes gains relevant prominence. In this context, the objective of this work was to map the height of coffee trees in a crop hit by frost. To this end, the present experiment was conducted in the rural area of the city of Santo Antônio do Amparo, on the Bom Jardim farm, in a coffee plantation (Cofea arabica L.) of the Catucaí red IAC 144 cultivar in an area of 3.5ha. In this area, a flight was carried out with a remotely piloted aircraft (Remotely Piloted Aircraft - RPA) on board with a LiDAR sensor (Zemuse L1). The data was analyzed and the mapping of the area's plant height was carried out using geoprocessing software. As a result, the mapping of the crop was obtained, identifying the spatial variability of the height of the coffee trees, making it possible, therefore, to identify the places where the heights of the plants presented lower values, being places more affected by frost and places where the plants presented higher values of height, and are therefore less affected by the frost event.
KEYWORDS: Laser scanner; coffee farming; drone

INTRODUÇÃO

A cafeicultura é responsável por um valor significativo da produção brasileira e mundial, o Brasil é o maior produtor mundial de café, sendo destaque com um dos maiores geradores de riquezas e um dos produtos mais importante da história nacional (Brainer, 2021). Ainda em crescimento e dada a sua importância na estrutura econômica do país (Chies et al 2012), o cultivo de cafeeiros requer

técnicas de monitoramento e estratégias para melhorar suas condições de produção (Lopes, 2014). Nos dias atuais um dos desafios enfrentados pelos cafeicultores, como lembra Taiz et al. (2017) e Cezar et al. (2015),são as condições e eventos climáticos. Um evento, que afeta muitas lavouras cafeeiras é a geada, pois seus efeitos são visíveis nas plantas, a massa de ar gelada que sobrepõem as lavouras, ocasiona a queima gerando prejuízos ao produtor, o que torna necessário novas técnicas que possibilitem a obtenção de informações das plantas cafeeiras e que possam ocasionar a redução de visitas a campo e aumentar a eficiência no processo de tomada de decisão.

OBJETIVOS

O presente trabalho tem como objetivo avaliar e analisar dados de altura de plantas geoprocessados a partir de levantamentos aéreos realizados com a tecnologia LiDAR em uma área cafeeira afetada por geada.

MATERIAL E MÉTODOS

O presente experimento foi conduzido na zona rural da cidade de Santo Antônio do Amparo, na fazenda Bom Jardim, em uma lavoura cafeeira (*Cofea arabica* L.) da cultivar Catucaí vermelho IAC 144, plantada no ano de 2015, situada no ponto de confluência entre o sul e o oeste de Minas Gerais, Brasil. A lavoura adotada para experimentação está caracterizada na projeção UTM, Datum WGS 84, zona 23S e coordenadas 7677527.305288N e 603932.761361W, com altitude média de 977m e solo classificado como Latossolo vermelho-amarelo distrófico e possui uma área de 3,5ha. A geada ocorreu no dia 20 de julho de 2021, a temperatura mínima observada em termômetro localizado na área de estudo foi de -1,7°C e o vôo em maio de 2023. Para a realização do presente estudo foi utilizada uma aeronave remotamente pilotada (RPA) do tipo quadricóptero, da marca DJI modelo Matrice 300 com sistema de posicionamento global RTK (Figura 1a). Esta RPA apresenta 55 minutos autonomia de voo, sistema de detecção e posicionamento em seis direções, sistema de transmissão aperfeiçoado e câmbio de frequência automática em tempo real entre as faixas 2,4 e 5,8 GHz, resultando em uma maior estabilidade de voo em áreas com alta taxa de interferência, como linhas de transmissão.

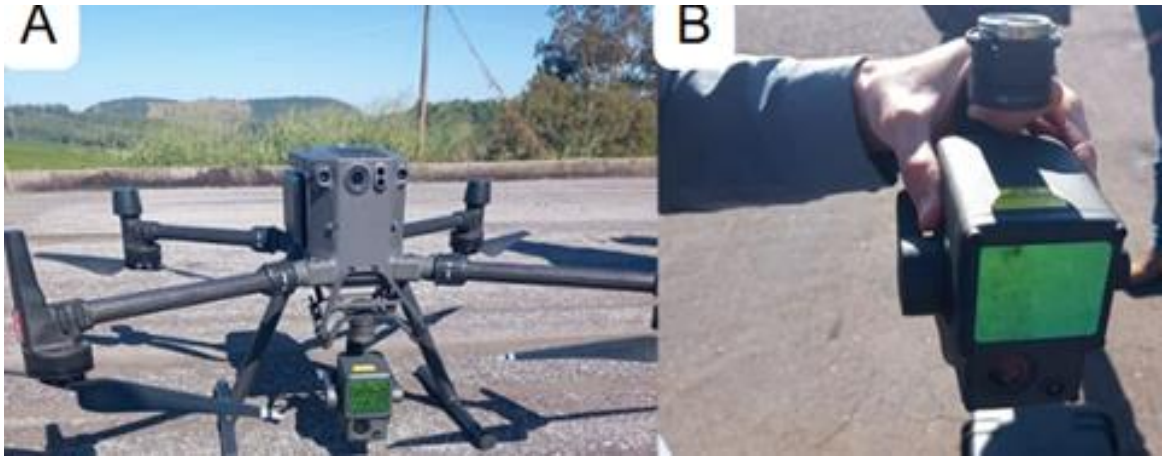


Figura 1. RPA Matrice 300 RTK (a) e partes integrantes do sensor Zenmuse L1 (b)

Foi utilizado o sensor embarcado Zenmuse L1 (Figura 1b), caracterizado com um módulo Livox LiDAR, um sistema de navegação inercial (IMU) de alta precisão e uma câmera RGB de 20 MP. O levantamento pela aeronave e pelo sensor gerou nuvens de pontos LiDAR georeferenciadas no formato (*.LAS)*, cujos dados foram processados no software DJI Terra. As nuvens de pontos foram georreferenciadas diretamente usando o sensor RTK do Matrice 300. A nuvem de pontos foi classificada automaticamente e em seguida manualmente para definição de pontos representantes do

terreno. A partir destes, foram gerados o modelo digital de superfície e modelo digital de terreno. Para a obtenção das alturas das plantas cafeeiras foi utilizado o método de diferenciação dos rasters dos modelos conforme descrito por Gonçalves (2018) juntamente com a posição do ortomosaico georreferenciado (Figura 2). Foram ainda realizada a analise descritiva para identificação das médias mínimos e máximos das alturas encontradas na análise e para o mapeamento das alturas na área foi realizados no software QGIS 3.30.2, que possibilitou identificar 3900 alturas das plantas georreferenciadas na área cafeeira (Figura 2).



Figura 2- Exemplo da identificação das plantas de café para obtenção de informações de altura

RESULTADOS E DISCUSSÃO

Inicialmente foram realizados analises descritivas nos dados para observar os valores médios, máximos e mínimos (Tabela 1).

TABELA 1 - Resultados da análise estatística descritiva da variável em estudo

Variavel	Média	Mínimo	Máximo
Altura	2.69	0.28	3.64

Assim obteve se como resultados pelo geoprocessamento a identificação das plantas a campo e o mapeamento das alturas das plantas cafeeiras as informações das regiões com maior e menor altura das plantas de café. Na Figura 3, pode-se observar que as regiões da extremidade ao norte são caracterizadas por plantas com menores alturas, o que pode ser justificado pela ocorrência de geada de forma mais acentuada na região, afetando, portanto, o crescimento das plantas. Já na região ao sul, observou-se plantas com maiores alturas, sendo que esta região foi menos acometida pelo evento geada. A tecnologia LiDAR consorciada com o geoprocessamento se mostrou eficaz em apresentar as condições das plantas cafeeiras nas regiões no mapa com alta incidência e baixa incidência da ocorrência de geada, mesmo após o ocorrido, visto que os resultados visuais no mapa, caracterizaram efetivamente as regiões com informações de altura de plantas cafeeiras, com valores superiores e valores inferiores. Marin et al. (2019) observou através de técnicas de geoprocessamento consorciada com sensores multiespectrais que, nesta mesma área, os índices de vegetação apresentaram resultados satisfatórios na identificação de zonas de plantas atingidas por geada e plantas com menores incidências da geada. Assim pode se afirmar que a tecnologia LiDAR associada ao geoprocessamento se mostrou eficaz para obter identificar regiões afetadas por geada.

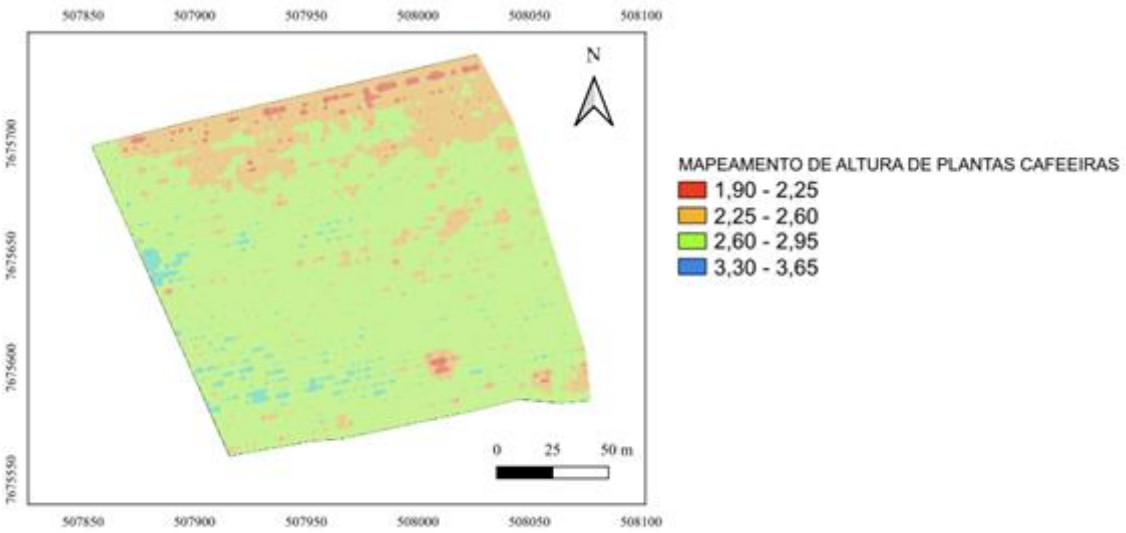


Figura 3 - Mapeamento do atributo altura de altura

CONCLUSÃO

Os resultados obtidos pelo geoprocessamento e pelo sensor LiDAR se mostraram satisfatórios na identificação e mapeamento da altura na lavoura em uma lavoura cafeeira afetada pelo evento geada, possibilitando a identificação das áreas mais e menos afetadas por este evento climático.

AGRADECIMENTOS

EMBRAPA Café - Consórcio Pesquisa Café (projeto 10.18.20.041.00.00), CNPq (projeto 310186/2023-4), FAPEMIG (projetoAPQ-00661-22), CAPES, UFLA e PPGEA/UFLA.

REFERÊNCIAS

BRAINER, Maria Simone de Castro Pereira; XIMENES, Luciano Feijão. Produção e mercado do café. 2021.

CESAR, Julio; LUÍS, Edson; SP, Cândido Mota; MEIO, P. O. R.; VEGETAÇÃO, D. E. Índices D. E. Análise dos efeitos de geadas na cobertura vegetal do município de Cândido Mota-SP, Brasil, por meio de Índices de Vegetação. [S. l.], 2015.

CHIES, Cláudia; YOKOO, Sandra. Colonização do norte paranaense: avanço da cafeicultura e problemas decorrentes deste processo. Revista GEOMAE, v. 3, n. 1, p. 27-44, 2012.

GONÇALVES. Estimativas de parametrosbiofisicos de lavoura de cafeeira a partir de imagens obtidas por aeronaves remotamente pilotadas.2018. Tese de Doutorado

Moran, P.A.P. Notes oncontinuousstochasticphenomena. Biometrika, v. 37, n. 1/2, p. 17-23, 1950.

TAIZ, L. et al. Fisiologia e desenvolvimento vegetal. 6.ed. Porto Alegre: Artmed, 2017. 858p.

LOPES, Paulo Rogério. A biodiversidade como fator preponderante para a produção agrícola em agroecossistemas cafeeiros sombreados no Pontal do Paranapanema. 2014. Tese de Doutorado. Universidade de São Paulo.

DIAGNÓSTICO DE MURCHAS VASCULARES DO FEIJOEIRO COMUM COM SENSOR HIPERESPECTRAL

ANDRESSA DE SOUZA ALMEIDA [1]; JUSTINO JOSÉ DIAS NETO [2]; WILLIAM RAFAEL RIBEIRO [2]; LAURA CRISTINA DA SILVA ALMEIDA [3]; LETÍCIA DANIELLA MARTINS PARREIRA [3]; RENATA PIRES BATISTA [3]; MÔNICA HITOMI OKURA [4]; ALAERSON MAIA GERALDINE [5]; TAVVS MICAEL ALVES [5]; MURILLO LOBO JUNIOR [6]; RÔMULO MOREIRA SILVA [2]

[1]Doutoranda em Agronomia. Goiânia - GO. Universidade Federal de Goiás; [2]Bolsista. Santo Antônio de Goiás - GO. Embrapa Arroz e Feijão; [3]Mestranda em Agronomia. Goiânia - GO. Universidade Federal de Goiás; [4]Docente. Uberaba -MG. Universidade Federal do Triângulo Mineiro; [5]Docente. Rio Verde -GO. Instituto Federal Goiano; [6]Pesquisador. Santo Antônio de Goiás - GO. Embrapa Arroz e Feijão

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

As murchas vasculares causadas pelos patógenos *Fusarium oxysporum* f. sp. *phaseoli* e *Curtobacterium flaccumfaciens* pv. *flaccumfaciens* impactam negativamente a cultura do feijoeiro comum (*Phaseolus vulgaris* L.), resultando em perdas significativas de produtividade. O objetivo deste estudo foi avaliar a eficácia de um sensor hiperespectral no diagnóstico precoce de murchas vasculares e na diferenciação entre plantas saudáveis e infectadas por cada um destes patógenos. O diagnóstico precoce é crucial para antecipar medidas de manejo e minimizar a severidade das doenças. O experimento foi conduzido na Embrapa Arroz e Feijão, na safra de inverno de 2022. Foram testadas quatro cultivares de feijão tipo Carioca em 12 tratamentos (com e sem inoculação dos patógenos nas sementes), com 10 repetições em delineamento em blocos ao acaso. As imagens hiperespectrais foram capturadas no estágio fenológico V4 da cultura, antes da manifestação de sintomas visuais, utilizando o sensor hiperespectral. As imagens foram processadas para analisar a reflectância das plantas em uma faixa espectral de 400 a 1000 nm, abrangendo 271 bandas. Foi realizada uma análise de regressão (α= 0,05) para identificar plantas saudáveis e doentes. O sensoriamento remoto foi capaz de identificar infecções pré-sintomáticas nas quatro cultivares. As assinaturas espectrais variaram entre as doenças, endossando a resistência da cultivar BRS FC402 à murcha de Fusarium, e a susceptibilidade da cultivar BRS Estilo. Além disso, a cultivar BRS FC310 mostrou resistência à murcha de Curtobacterium, ao contrário da susceptibilidade na cultivar BRSMG Madrepérola.

PALAVRAS-CHAVE: Imagem hiperespectral; Diagnose precoce; Sensoriamento remoto

ABSTRACT

Vascular wilts caused by the pathogens *Fusarium oxysporum* f. sp. *phaseoli* and *Curtobacterium flaccumfaciens* pv. *flaccumfaciens* negatively impact common bean (Phaseolus vulgaris L.) crops, resulting in significant productivity losses. The objective of this study was to evaluate the effectiveness of a hyperspectral sensor in the early diagnosis of vascular wilts and in differentiating between healthy plants and those infected by each of these pathogens. Early diagnosis is crucial for anticipating management measures and minimizing disease severity. The experiment was conducted at Embrapa Arroz e Feijão during the winter 2022 season. Four Carioca-type bean cultivars were tested in 12 treatments (with and without pathogen inoculation in the seeds), with 10 replications in a randomized block design. Hyperspectral images were captured at the V4 phenological stage of the crop, prior to the appearance of visual symptoms, using a hyperspectral sensor. The images were processed to analyze plant reflectance within a spectral range of 400 to 1000 nm, covering 271 bands. A regression analysis (α = 0.05) was performed to identify healthy and diseased plants. Remote sensing successfully identified pre-symptomatic infections in all four cultivars. Spectral signatures varied between the diseases, confirming the resistance of the cultivar BRS FC402 to Fusarium wilt

and the susceptibility of the cultivar BRS Estilo. Additionally, the cultivar BRS FC310 showed resistance to Curtobacterium wilt, in contrast to the susceptibility observed in the cultivar BRSMG Madrepérola.

KEYWORDS: Hyperspectral imaging ; Early diagnosis; Remote sensing

INTRODUÇÃO

O feijoeiro comum (*Phaseolus vulgaris* L.) é a principal fonte de proteína vegetal no Brasil. Recentemente, a cultura ganhou destaque como alimento funcional por seus benefícios na prevenção de doenças crônicas, tornando-se essencial em dietas vegetarianas, veganas e funcionais. No entanto seu cultivo é desafiado por diversas doenças que variam sasonal e geograficamente conforme o ambiente. Um diagnóstico preciso dessas doenças é fundamental para um manejo integrado eficaz, visando minimizar perdas de produtividade e promover uma agricultura sustentável. (CARBONELL; CHIORATO; BEZERRA, 2021; WENDLAND; LOBO-JUNIOR; FARIA, 2018).

Duas murchas vasculares afetam negativamente o feijoeiro comum, pois plantas suscetíveis podem ser infectadas precocemente, perdem turgescência em especial a partir do seu florescimento e acabam morrendo. Estas doenças são causadas pelos patógenos *Curtobacterium flaccumfaciens* pv. *flaccumfaciens* e *Fusarium oxysporum* f. sp. *phaseoli*. Ambos os patógenos provocam murchamento irreversível das plantas e apresentam sintomas muito semelhantes, o que dificulta a identificação visual precisa das doenças. Devido à complexidade na diferenciação entre ambos os agentes causais em campo, é essencial desenvolver métodos para diagnóstico mais precisos, rápidos e confiáveis. Potencialmente, o sensoriamento remoto pode atender estas demandas e contribuir para um manejo integrado mais eficaz das murchas vasculares. Atualmente, tecnologias avançadas de análise de imagens, como sensores visíveis, hiperespectrais e multiespectrais podem viabilizar o diagnóstico de doenças antes do surgimento de sintomas e estimar a severidade das doenças das plantas, auxiliando no seu manejo e na redução de perdas na produção (BOCK et al., 2020; CHU et al., 2022; WENDLAND; LOBO-JUNIOR; FARIA, 2018).

OBJETIVOS

O objetivo deste estudo foi avaliar a eficácia de um sensor hiperespectral na diferenciação entre plantas saudáveis e doentes, além de verificar sua capacidade de diagnosticar de forma precoce murchas vasculares na cultura do feijoeiro comum.

MATERIAL E MÉTODOS

O experimento foi conduzido na Embrapa Arroz e Feijão. As cepas dos isolados de *F. oxysporum* f. sp. *phaseoli* e *C. flaccumfaciens* pv. *flaccumfaciens* empregados neste estudo pertencem à Coleção de Microrganismos e Fungos Multifuncionais da Embrapa Arroz e Feijão. Foram utilizadas sementes de quatro genótipos de feijão do tipo Carioca com 12 tratamentos (BRS Estilo, BRS FC402, BRSMG Madrepérola e BRS FC310) incluindo sementes com tratamento químico utilizadas nas bordaduras, e sementes inoculadas ou não com os patógenos e sem tratamento químico com 10 repetições dispostas em DBC, durante a safra de inverno de 2022. Os ensaios foram conduzidos com plantio em semeadura direta, sobre palhada de braquiária (*Urochloa ruziziensis*). A captura de imagens foi realizada no estádio V4 da cultura, antes do aparecimento de sintomas visuais. Para a captura de imagens hiperespectrais foi utilizado o sensor Headwall Nano-Hyperspec® acoplado em um drone DJI MATRICE™ M600 Pro (M600Pro). As imagens foram processadas para obter os valores referentes ao espectro emitido pelas plantas sadias e infectadas, com resultados submetidos à análise de regressão (α= 0,05) para a identificação de plantas saudáveis e doentes a partir da medição da reflectância em uma faixa espectral de 400 a 1000 nm em 271 bandas.

RESULTADOS E DISCUSSÃO

As assinaturas espectrais foram distintas para ambas as doenças e endossaram a resistência da cultivar BRS FC402 e a suscetibilidade da cultivar BRS Estilo (Figura 1) à murcha de Fusarium. Os valores mais elevados de R^2 dos modelos ajustados foram observados em 700 nm, indicando que a reflectância nesse comprimento de onda é a mais relevante para diagnosticar precocemente a murcha de Fusarium nas cultivares suscetíveis. Não houve diferença na refletância da cultivar BRS FC402 independentemente de inoculação ou tratamento aplicado. As bandas observadas estão dentro da faixa visível do espectro eletromagnético, com o espectro de luz em 700 nm situado na faixa do vermelho, que é o limite superior da luz visível para o olho humano. Para a murcha de Curtobacterium, foi confirmada a resistência da BRS FC310 a *C. flaccumfaciens* pv. *flaccumfaciens*, enquanto a cultivar BRSMG Madrepérola mostrou suscetibilidade à doença. Os maiores R^2 dos modelos ajustados apresentaram espectros distintos: a banda no modelo de melhor ajuste observada na cultivar BRSMG Madrepérola se encontra na faixa do infravermelho, logo acima de 700 nm (Figura 2). A BRS Estilo apresentou melhor ajuste de modelo na faixa de 700 nm, enquanto a BRS FC402 mostrou diferenças entre plantas sadias e infectadas em todo o espectro visível, de 400 a 700 nm. Aos 700 nanômetros, a luz começa a se aproximar do infravermelho próximo (NIR), considerado importante em várias aplicações do sensoriamento remoto na agricultura de precisão, onde o comportamento da luz nessa banda pode fornecer informações valiosas sobre a saúde das plantas (SANTOS, 2017; JENSEN 2007; GATES et al. 1965).

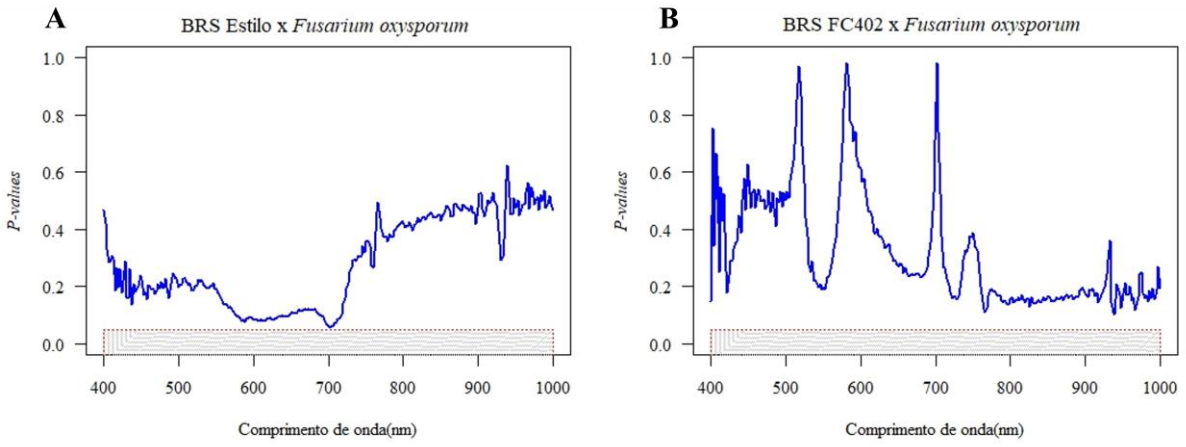


FIGURA 1. P-valores de análises de regressão comparando diferenças na resposta espectral (400 a 1000 nm) de plantas assintomáticas das cultivares de feijão BRS Estilo (A) e BRS FC402 (B), respectivamente suscetível e resistente a *Fusarium oxysporum* f. sp. *phaseoli*. A barra cinza indica significância a 5%.

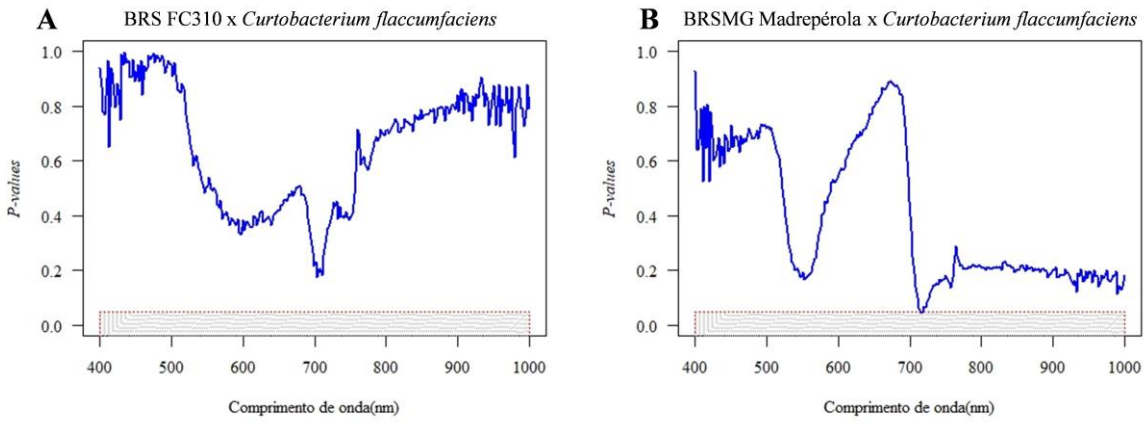


FIGURA 2. P-valores de análises de regressão comparando diferenças na resposta espectral (400 a 1000 nm) de plantas assintomáticas das cultivares de feijão BRS FC310 (A) e BRSMG Madrepérola (B), respectivamente resistente e suscetível a *Curtobacterium flaccumfaciens* pv. *flaccumfaciens.* A barra cinza indica significância a 5%.

CONCLUSÃO

O sensor hiperespectral foi capaz de identificar precocemente murchas vasculares nas quatro cultivares de feijão comum. As assinaturas espectrais foram diferentes para ambas as doenças, confirmando a resistência da BRS FC402 para a murcha de *Fusarium*, e a susceptibilidade da cultivar BRS Estilo. A resistência da cultivar BRS FC310 à murcha de *Curtobacterium* foi evidenciada, ao contrário da susceptibilidade da cultivar BRSMG Madrepérola.

AGRADECIMENTOS

À FAPEG, FAPED, CAPES e CNPq pelas bolsas de estudo concedidas.

REFERÊNCIAS

BOCK, C.H., BARBEDO, J.G.A., DEL PONTE, E.M. *et al.* From visual estimates to fully automated sensor-based measurements of plant disease severity: status and challenges for improving accuracy**.** ***Phytopathol Res*** **2**, 9, 2020. https://doi.org/10.1186/s42483-020-00049-8

CARBONELL, S. A. M.; CHIORATO, A. F.; BEZERRA, L. M. C. A planta e o grão de feijão e as formas de apresentação aos consumidores. In: FERREIRA, C. M.; BARRIGOSSI, J. A. F. (ed.). Arroz e feijão: tradição e segurança alimentar. Brasília, DF: **Embrapa**; Santo Antônio de Goiás: Embrapa Arroz e Feijão, 2021. Disponível em: <http://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/1134410>

CHU, H., ZHANG, C., WANG, M., GOUDA, M., WEI, X., HE, Y., LIU, Y., Hyperspectral imaging with shallow convolutional neural networks (SCNN) predicts the early herbicide stress in wheat cultivars. **J. Hard Mater.** 421, 126706, 2022. http://dx.doi.org/10.1016/j.jhazmat.2021.126706

GATES, D.M., Keegan, H.J., Schleter, J.C., Weidner, V.R. Spectral properties of plants. **Applied Optics**, 4(1), 11-20. 1965.

JENSEN, J.R. Remote Sensing of the Environment: An Earth Resource Perspective. 2nd Edition, **Pearson Prentice Hall**. 2007.

SANTOS, M. R. Desenvolvimento de um sistema de visão computacional para fenotipagem de alta precisão. 2017. 90 f. **Dissertação** (Mestrado em Computação Aplicada) - Universidade de Passo Fundo, Passo Fundo, 2017.

WENDLAND, A.; LOBO JUNIOR, M.; FARIA, J. C. Manual de identificação das principais doenças do feijoeiro-comum. Brasília, DF: **Embrapa**, 2018. Disponível em: https://ainfo.cnptia.embrapa.br/digital/bitstream/item/192413/1/CNPAF-2018-ManIdentDoenFeijao.pdf

CORRELAÇÃO ENTRE ÍNDICES DE VEGETAÇÃO SUBORBITAL E PROXIMAL COM O ÍNDICE RELATIVO DO TEOR FOLIAR DE CLOROFILA EM VIDEIRA 'Syrah'

ANDERSON DE JESUS PEREIRA [1]; ISRAEL DE OLIVIERA JUNIOR [2]; LÚCIO ANDRÉ DE CASTRO JORGE [3]; LUIS HENRIQUE BASSOI [4]

[1]Doutorando em Engenharia Agrícola. Av. Prof. Montenegro, s/n - Vila Paraiso, Botucatu - SP, 18618-687. Universidade Estadual Paulista; [2]Doutor em Geografia. Tv. J J Seabra, 158 - Estacao, Jacobina - BA, 44700-000. Universidade do Estado da Bahia; [3]Doutor em Engenharia Elétrica. R. 15 de Novembro, 1452 - Centro, São Carlos - SP, 13560-970. Embrapa Instrumentação; [4]Doutor em Ciências. R. 15 de Novembro, 1452 - Centro, São Carlos - SP, 13560-970. Embrapa Instrumentação

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Diversos índices de vegetação (IV) têm sido desenvolvidos para estimar a variabilidade espacial do conteúdo foliar de clorofila em áreas agrícolas. Nesse sentido, em um vinhedo com plantas conduzidas em espaldeira e irrigado por gotejamento em Ribeirão Preto-SP, foi analisada a correlação entre índices de vegetação suborbital obtidos por meio do sensor MicaSense RedEdge-M, índices de vegetação proximais adquiridos por meio do sensor Crop Circle ACS-430 e o índice relativo do teor de clorofila total nas folhas da videira 'Syrah' medido com o sensor portátil clorofiLOG CFL 1030. Os dados coletados foram submetidos a uma análise de normalidade e homoscedasticidade dos resíduos em um nível de significância de 5%. Posteriormente, foram realizadas as análises de correlação linear e regressão dos índices de vegetação proximais e suborbitais e do índice relativo de clorofila total. O índice do conteúdo de clorofila no dossel (CCCI) foi o IV que obteve a melhor correlação de Pearson em ambos os métodos (proximal e suborbital), seguido pela diferença normalizada do vermelho limítrofe (NDRE). Em todas as análises, os IV oriundos do sensor suborbital alcançaram correlação maiores quando comparado com o sensor proximal. Assim, IV que utilizam o comprimento de onda na região do vermelho limítrofe (RedEedge) tem maiores correlações com o índice relativo do teor de clorofila total nas folhas de videira.

PALAVRAS-CHAVE: Vitivinicultura de precisão; Vinhos de inverno; Monitoramento

ABSTRACT

Several vegetation indices (VI) have been developed to estimate the spatial variability of leaf chlorophyll content in agricultural areas. In this sense, in a 'Syrah' vineyard with plants grown in espalier and irrigated by drip in Ribeirão Preto, state of São Paulo, Brazil, suborbital vegetation indices obtained through the MicaSense RedEdge-M sensor, proximal vegetation indices acquired through the Crop Circle ACS-430 and the relative indice of leaf chlorophyll content measured with the portable sensor chlorofiLOG CFL 1030 were correlated. Data were subjected to an analysis of normality and homoscedasticity of residues at a significance level of 5%. Subsequently, linear correlation and regression analyzes of the proximal and suborbital VI and relative indice were carried out. The canopy chlorophyll content indice (CCCI) was the IV that obtained the best Pearson correlation in both methods (proximal and suborbital), followed by normalized difference of red edge (NDRE). In all analyses, VI from the suborbital sensor achieved higher correlations when compared to the proximal sensor. Thus, VI that uses wavelengths in red edge region has greater correlations with the relative indice of chlorophyll content in grapevine leaves.

KEYWORDS: ;;

INTRODUÇÃO

A agricultura de precisão tem se tornado um método importante de análise e gestão de vinhedos irrigados (SARRI *et al.*, 2020), em face dos condicionantes ambientais que interagem no vigor vegetativo e, por conseguinte, nas variações da qualidade dos frutos. A utilização de aeronave remotamente pilotada (RPA) apresenta diversas aplicabilidades nas Ciências Agrárias e Ambientais, como a captura de imagens suborbitais, que possibilitam a obtenção de índices de vegetação (IV) e a correlação com distintas fontes de dados, como os sistemas de reflectância proximal e índices do teor foliar de clorofila (LOURES *et al.*, 2020; DELAVARPOUR *et al*., 2021). O monitoramento do vigor vegetativo pelos IV é um conteúdo relevante para a vitivinicultura de precisão (RADOCAJ *et al*., 2023), porque derivam em diversos produtos, como os cartográficos, que possibilitam avaliar padrões espaciais e temporais de mudanças em áreas agrícolas mediante os estágios fenológicos das plantas e alterações no ambiente de produção, de importância para associar com os rendimentos. Já as informações sobre clorofila encontram-se entre as mais importantes nas avaliações agronômicas, ao conceber investigações diretas sobre estado dos nutrientes, vigor da planta, rendimento e, ainda indiretamente, teor de nitrogênio do solo e fertilização ideal (CARMONA *et al*., 2015). Os materiais e métodos supracitados para a aplicação da agricultura de precisão vem somar com os meios metodológicos que encurtam o tempo, os custos da gestão dos vinhedos e diminuem o emprego de amostragens destrutivas (AMMONIACI *et al.*, 2021; CARMONA *et al*., 2015). O uso da agricultura de precisão na vitivinicultura é um meio considerável para tornar a atividade rentável e competitiva em um mercado exigente quanto à produtividade agrícola e qualidade das bagas e dos vinhos. Assim, este estudo tem como objetivo analisar o desempenho e a correlação entre IV suborbital e proximal com o índice relativo do teor de clorofila total em um vinhedo irrigado.

OBJETIVOS

Analisar o desempenho e a correlação entre IV suborbital e proximal com o índice relativo do teor de clorofila total em um vinhedo irrigado.

MATERIAL E MÉTODOS

O trabalho foi desenvolvido em um vinhedo comercial situado no município de Ribeirão Preto-SP (21°17'24,53" S 47°50'46,83" O), com a videira (*Vitis vinifera* L.) cv. *Syrah*, destinadas à produção de vinhos de inverno. A área possui 1,1 ha, e as videiras foram cultivadas no espancamento 2,8 x 1 m entre fileiras e plantas, respectivamente, conduzidas em sistema de espaldeira, irrigadas por gotejamento, com poda de formação do tipo cordão Royat bilateral, e submetidas ao sistema de dupla poda anual. Os dados de refletância foram coletados no dia 12 de maio de 2021, 100 dias após a poda de produção no estádio maturação de bagas.

Os dados suborbitais foram coletados mediante ao uso da aeronave remotamente pilotada (RPA), multirotor, modelo DJI Inspire 2. A câmera acoplada à RPA correspondeu ao sensor multiespectral RedEdge-M (MicaSense, USA) capaz de capturar reflectâncias nas bandas do azul (475 nm, ± 32 nm), verde (560 nm, ± 27), vermelho (668 nm, ± 14), vermelho limítrofe (717 nm, ± 12) e infravermelho próximo (842 nm, ± 57). A altura de voo limitou-se a 30 m, o que gerou imagens com resolução espacial de dois centímetros (0,02 m), com sobreposição frontal e lateral definida em 75%. As imagens foram processadas no *software* Agisoft ™ MetaShape, versão 1.5.3 (Agisoft LLC, Rússia), em que realizou a calibração radiométrica por meio do painel de calibração da Micasense, no qual possui valores de refletância definidos individualmente para cada painel. Em sequência, ocorreu o alinhamento das imagens com qualidade elevada; inserção de 4 pontos de controle em solo, georreferenciados por receptores HiPer GGD (Topcon, USA) do Global Navigation Satellite System (GNSS), com o sinal corrigido pelo Real Time Kinematic (RTK), com precisão de aproximadamente ± 1 cm; construção da nuvem densa de pontos (qualidade elevada); geração do modelo digital de terreno (MDT) e do ortomosaico. Aplicou a classificação supervisionada por intermédio do semi-automatic classification plugin (SCP) no *software* QGIS (versão 3.16.14, Hannover). O algoritmo

maximum likelihood (ML) obteve um melhor desempenho em distinguir os objetos na imagem, assim houve a segmentação do dossel com o intuito de isolar somete o objeto de interesse, referente ao dossel.

Os dados de reflectância proximal foram adquiridos pelo sensor portátil Crop Circle ACS-430 acoplado ao datalogger GeoSCOUT GLS-400 (Holand Scientific Inc., EUA) e ao receptor global navigation satellite system (GNSS) Hiper GGD. O sensor é capaz de medir simultaneamente informações em três comprimentos de onda, no espectro do vermelho (670 nm), vermelho limítrofe (730 nm) e o infravermelho próximo (780 nm). Durante a coleta, o equipamento foi programado para aquisição de 10 medidas por segundo. Posicionou o sensor ACS-430 no topo do dossel para obter os dados de reflectância vertical a uma distância de 0,30 m do topo das videiras. O deslocamento ocorreu por caminhamento ao longo de todas as fileiras de plantas do vinhedo.

Pelos dados de refletância suborbital e proximal, foram calculados cinco índices de vegetação (IV), referentes ao índice do conteúdo de clorofila no dossel (CCCI), razão simples modificada (MSR), diferença normalizada do vermelho limítrofe (NDRE) e índice de vegetação por diferença normalizada (NDVI).

Para obter os dados de clorofila *a* e *b* e total (*a*+*b*), utilizou o medidor portátil não destrutivo ClorofiLOG, modelo CFL 1030 (Falker Automação Agrícola, Brasil). O equipamento emite três comprimentos de onda, dois no espectro eletromagnético do vermelho (635 e 660 nm), onde ocorrem os maiores picos de absorção; e o outro no infravermelho próximo (880 nm). As informações foram colhidas no dia 11 de maio de 2021, em cinco folhas por planta totalmente expandidas, saudáveis, sem a ocorrência de doenças ou pragas, posicionadas entre o terço médio e o terço superior. As leituras foram realizadas no eixo abaxial das folhas. Com as cinco leituras referentes à planta individual, calculou uma média que totalizaram 57 dados amostrais distribuídos pelo campo.

As correlações lineares de Pearson (r) foram categorizadas de acordo com os intervalos proposto por Schober *et al*. (2018), com base em cinco classes: muito fraca ($0 < r < 0,19$); fraca ($0,20 < r < 0,39$); moderada ($0,40 < r < 0,69$); forte ($0,70 < r < 0,89$), e muito forte ($0,90 < r < 1$).

RESULTADOS E DISCUSSÃO

O CCCI alcançou uma forte correlação ($0,70 < r < 0,89$) com o IRC e resultou em um (r) de 0,80. Os índices MSR, RDVI, NDRE e NDVI foram classificados como correlação moderada ($0,40 < r < 0,69$), significativos a 0,1% (Tabela 1). O NDVI é um índice tradicional, comumente utilizado na agricultura para o monitoramento da biomassa e do vigor vegetativo. Esse índice não obteve um desempenho satisfatório para o (R^2), pois equivaleu a 0,34, correlação fraca ($0,20 < r < 0,39$); já o MSR correspondeu a 0,42 e o RDV a 0,24 (Tabela 1). Resultados semelhantes de coeficiente de determinação foram encontrados por Zarco-Tejada *et al.* (2005) ao correlacioná-los com o teor de clorofila total, os quais referiram a 0,26 para o NDVI, 0,34 para MSR e 0,33 para o RDVI.

TABELA 1 - Coeficiente de correlação de Pearson (r) e coeficiente de determinação (R^2): índices de vegetação multiespectrais suborbital, clorofila total (a + b), aplicados na *Vitis vinifera* L. cv. *Syrah, dados coletados em Ribeirão Preto-SP, ciclo 2021.*

Índice de vegetação	Suborbital		
	r	R^2	Equação
CCCI	0,80**	0,64	y=51,957x+14,503
MSR	0,65**	0,42	y=6,789x+20,900

NDRE	0,66**	0,44	y= 50,257x+20,343
NDVI	0,58**	0,34	y= 48,4506x-0,4675
RDVI	0,49**	0,24	y=27,520x+21,625

**, *: significância estatística ao nível de 0,1 % (α = 0,001), 1% (α = 0,01); y = IRC; x = valor médio do índice de vegetação suborbital

Todos os IV proximais obtiveram correlações significativas com a clorofila total (Tabela 2). Ressalta-se que o CCCI e NDRE obtiveram os maiores valores de R^2, que referiram, respectivamente, a 0,46 e 0,42 ($p < 0,001$), seguidos pelo MSR (R^2=0,33) e NDVI (R^2=0,19). Embora, os índices gerados pelo sensor proximal tenham alcançados valores significativos, os maiores resultados apresentaram uma correlação moderada ($0,40 \leq r < 0,69$). Para o NDVI, obteve-se um (r) de 0,43 ($p<0,001$). Os dados são semelhantes aos relatados por Junges *et al.* (2019), que realizaram medições em campo do teor total de clorofila estimado por equipamento portátil proximal e constataram uma correlação positiva com o NDVI de 0,48 ($p<0,01$) na videira 'Chardonnay'.

TABELA 2 - Coeficiente de correlação de Pearson (r) e coeficiente de determinação (R^2): índices de vegetação multiespectrais proximais, clorofila total (a + b) aplicados na *Vitis vinifera* L. cv. *Syrah, dados coletados em Ribeirão Preto-SP, ciclo 2021.*

Índice de vegetação	Proximal		
	r	R^2	Equação
CCCI	0,68**	0,46	y=84,527x+3,344
MSR	0,59**	0,33	y=2,0884x+15,5024
NDRE	0,64**	0,42	y=81,956+10,394
NDVI	0,43**	0,19	y= 90,73-37,47
RDVI	0,35*	0,12	y=6,588x+1,473

***, *: significância estatística ao nível de 0,1 % (α = 0,001), 1% (α = 0,01); y = IRC; x = valor médio do índice de vegetação proximal

Os IV que constataram um melhor desempenho com o teor de clorofila foram o NDRE e CCCI. Ambos apresentam uma característica em comum, que é a utilização do comprimento de onda na região do vermelho limítrofe (RedEdge) nas proximidades de 700 nm. A refletância nesta região é considerada como um indicador sensível do conteúdo de clorofila foliar (GATES *et al.*, 1965; HORLER *et al.*, 1983; GITELSON *et al.*, 2004). Esses índices são indicados para determinar zonas homogêneas de vigor vegetativo em virtude da forte interação do dossel com a banda do RedEdge e do conteúdo de clorofila. O teor de clorofila nas folhas representa o estado de crescimento das culturas, e a estimação precisa desse componente é útil para aplicações agrícolas devido à relação estreita com as concentrações de nitrogênio.

Assim, o manejo espacial diferenciado do nitrogênio foliar (N) pode ser utilizado no vinhedo, uma vez que esse nutriente atua na formação dos pigmentos fotossintetizantes, a exemplo da clorofila, carotenoides e as ficobilinas (TAIZ; ZEIGER, 2008).

Índices tradicionais utilizados comumente no acompanhamento da vegetação, como o SR, RDVI e NDVI, não tiveram resultados superiores quando comparados com índices que abordam a faixa do

vermelho limítrofe (RedEdge), o que também foi observado por em videiras. A relação entre os IV gerados e a clorofila foi maior quando comparada com o sensoriamento remoto suborbital (Figura 1).

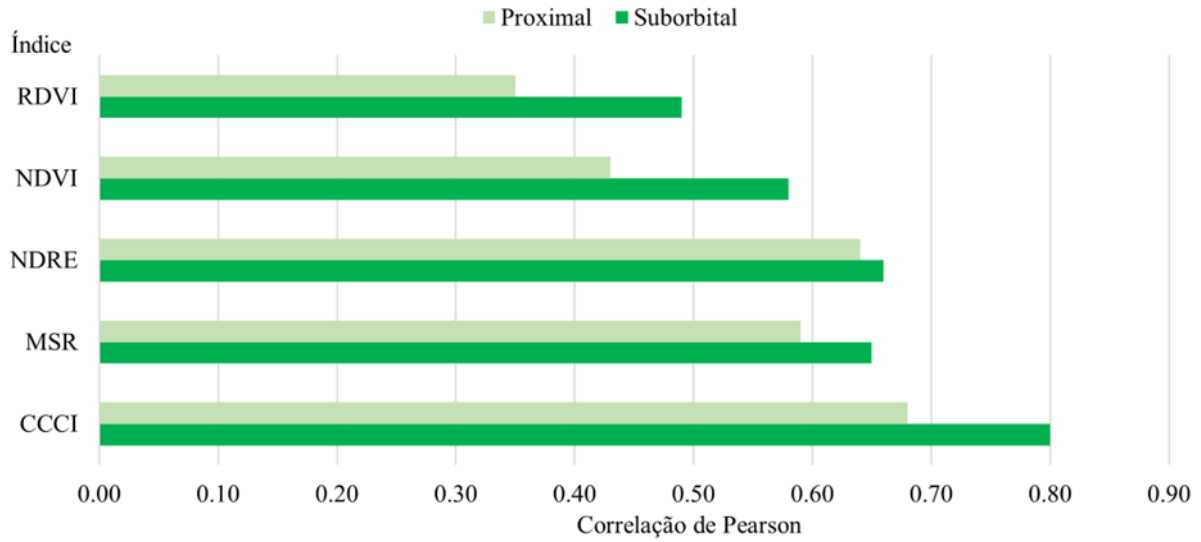


FIGURA 1 - Comparação entre as correlações da clorofila total e os índices de vegetação obtidos pelo sensor proximal e suborbital, aplicados na *Vitis vinifera* L. cv. *Syrah, dados coletados em Ribeirão Preto-SP, ciclo 2021*.

CONCLUSÃO

O uso de câmera multiespectral a bordo de uma aeronave remotamente pilotada possibilitou obter correlações mais altas entre o índice relativo do teor foliar clorofila total e os índices de vegetação suborbital em comparação com os IV calculados pelo sensor ativo proximal. Em ambos os métodos, houve o melhor desempenho dos IV que utilizam o comprimento de onda na região do vermelho limítrofe (RedEdge), a exemplo do CCCI e NDRE.

AGRADECIMENTOS

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de estudo, nível doutorado, ao primeiro autor; à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pelo apoio financeiro à pesquisa; à Vinícola Terras Altas pela cessão do vinhedo para realização do experimento.

REFERÊNCIAS

AMMONIACI, M.; KARTSIOTIS, S. P.; PERRIA, R.; STORCHI, P. State of the art of monitoring technologies and data processing for precision viticulture. **Agriculture**, v. 11, n. 3, 2021.

CARMONA, F.; RIVAS, R.; FONNEGRA, D. C. Vegetation index to estimate chlorophyll content from multispectral remote sensing data. **European Journal of Remote Sensing**, v. 48, n. 1, p. 319-326, 2015.

DELAVARPOUR, D.; KOPARAN, C.; NOWATZKI, J.; BAJWA, S.; SUN, X. A technical study on uav characteristics for precision agriculture applications and associated practical challenges. **Remote Sensing**, v. 13, n. 6, e1204, 2021.

GATES, D.M.; KEEGAN, H.J.; SCHLETER, J.C.; WEIDNER, V.R. Spectral Properties of Plants. **Applied Optics**, v. 4, n. 1, p. 11-20, 1965. DOI: 10.1364/AO.4.000011.

GITELSON, A. A. Wide dynamic range vegetation index for remote quantification of biophysical characteristics of vegetation. **Journal of Plant Physiology**, v. 161, p. 165-173, 2004.

HORLER, D. N. H.; DOCKRAY, M.; BARBER, J. The red edge of plant leaf reflectance. **International Journal of Remote Sensing**, v. 4, n. 2, p. 273-288, 1983.

JUNGES, A. H.; FONTANA, D. C.; ANZANELLO, A.; BREMM, C. Normalized difference vegetation index obtained by ground-based remote sensing to characterize vine cycle in Rio Grande do Sul, Brazil. Ciência e Agrotecnologia, v. 41, n. 5, p. 543- 553, 2017.

LOURES, L.; CHAMIZO, A.; FEREIRA, P.; LOURES, A.; CASTANHO, R.; PANAGOPOULOS, T. Assessing the effectiveness of precision agriculture management systems in Mediterranean small farms. **Sustainability**, v. 12, n. 9, e3765, 2020. DOI: 10.3390/su12093765.

MARTÍN, P.; ZARCO-TEJADA, P. J.; GONZÁLEZ, M. R.; BERJÓN, A. Using hyperspectral remote sensing to map grape quality in 'Tempranillo' vineyards affected by iron deficiency chlorosis. **Vitis**, v. 46, n. 1, p. 7-14, 2007.

RADOCAJ, D.; SILJEG, A.; MARINOVIC, R.; JURISIC, M. State of major vegetation indices in precision agriculture studies indexed in web of science: a review. Agriculture, v. 13, n. 3, e707, 2023.

SARRI, D.; LOMBARDO, S.; AGLIA, A.; PERNA, C.; LISCI, R.; PASCLAE, V.; RIMEDIOTTI, M.; NENCINI, G. VIERI, M. Smart farming introduction in wine farms: a systematic review and a new proposal. **Sustainability**, v. 12, n. 17, e7191, 2020.

SCHOBER, P.; BOER, C.;SCHWARTE, L. A. (2018). Correlation Coefficients: Appropriate Use and Interpretation. **Anesthesia & Analgesia**, v. 126, n. 5, p. 1763-1768, 2018.

TAIZ, L.; ZEIGER, E. **Fisiologia vegetal**. 3.ed. Porto Alegre: Artmed, 2008. 819p

ZARCO-TEJADA, P. J.; BERJÓNB, A.; LÓPEZ-LOZANO, R.; MILLER, J. R.; MARTÍNE, P.; CACHORRO, V.; GONZÁLEZE, M. R.; FRUTOS, A. Assessing vineyard condition with hyperspectral indices: Leaf and canopy reflectance simulation in a row-structured discontinuous canopy. **Remote Sensing of Environment**, v. 99, n. 3, p. 271-287, 2005.

FILTRAGEM DE MAPAS DE PRODUTIVIDADE PARA CRIAÇÃO DE MODELOS DE PREDIÇÃO POR SENSORIAMENTO REMOTO

Leonardo Correa Oliveira [1]; Cauê Henrique dos Santos [1]; João Vítor Fiolo Pozzuto [2]; Isabella Alves da Cunha [2]; Lucas Rios do Amaral [3]

[1]Discente. Cidade Universitária Zeferino Vaz - Barão Geraldo, Campinas - SP, 13083-970. Universidade Estadual de Campinas (UNICAMP); [2]Mestrando. Cidade Universitária Zeferino Vaz - Barão Geraldo, Campinas - SP, 13083-970. Universidade Estadual de Campinas (UNICAMP); [3]Docente. Cidade Universitária Zeferino Vaz - Barão Geraldo, Campinas - SP, 13083-970. Universidade Estadual de Campinas (UNICAMP)

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Na agricultura de precisão, os mapas de produtividade desempenham um papel fundamental na obtenção de informações sobre a resposta das culturas ao manejo adotado. Além disso, ao combinar dados de produtividade de safras anteriores com informações de sensoriamento remoto, é possível estimar como será o desempenho da próxima safra. Neste estudo, nosso objetivo foi investigar se o método de filtragem de dados influencia a precisão da predição da produtividade da soja. Testamos quatro métodos diferentes de filtragem: manualmente, utilizando o software MapFilter, uma combinação de MapFilter e filtragem manual, e utilizando a filtragem automática em uma plataforma digital. Verificamos que o método de filtragem influência no ajuste dos modelos de predição por sensoriamento remoto, sendo que o emprego do MapFilter pode entregar os melhores resultados de limpeza de dados de produtividade de soja, inclusive capturando maior dependência espacial.

PALAVRAS-CHAVE: Aprendizado de máquina; índice de vegetação; krigagem ordinária

ABSTRACT

In precision agriculture, yield maps play a fundamental role in obtaining information about crop response to adopted management practices. Furthermore, by combining data from previous crop yields with remote sensing information, it is possible to estimate the performance of the next harvest. In this study, our aim was to investigate whether the data filtering method influences the accuracy of soybean yield prediction. We tested four different filtering methods: manual filtering, using the MapFilter software, a combination of MapFilter and manual filtering, and automatic filtering using a digital platform. We found that the filtering method influences the fitting of remote sensing prediction models, with the use of MapFilter potentially yielding the best results in cleaning soybean yield data, including capturing greater spatial dependence.

KEYWORDS: ;

INTRODUÇÃO

Na agricultura de precisão, os mapas de produtividade obtidos por meio de monitores instalados nas colhedoras estão cada vez mais acessíveis devido aos avanços na mecanização e na troca de informações digitais. Esses dados fornecem informações concretas sobre como as culturas respondem ao manejo adotado e é considerado muitas vezes como ponto de partida para implementação da Agricultura de Precisão (Molin et. al., 2015). Frequentemente, esses dados são combinados com outras fontes, como o sensoriamento remoto, amplamente utilizado para monitorar as culturas (Amaral et. al., 2023). Essa integração de conjuntos de dados diversos possibilita insights mais abrangentes sobre as culturas, inclusive a capacidade de estimar a produtividade antes da colheita,

crucial para o planejamento eficaz do ciclo produtivo. No entanto, é comum encontrar outliers nesses dados devido a uma variedade de fatores durante a coleta, como ajustes na largura da plataforma, manobras da máquina ou falhas nos sensores (Menegatti e Molin, 2004). Assim, torna-se essencial aplicar métodos de filtragem para garantir que os dados representem com precisão a área em questão, permitindo o uso dessas informações de produtividade para enriquecer a análise. Nesse contexto, o objetivo deste estudo foi investigar variados métodos de filtragem e sua influência na precisão da predição da produtividade da soja com base em índices de vegetação.

OBJETIVOS

O atual trabalho tem como objetivo investigar os métodos de filtragem de dados e sua influencia à precisão da predição da produtividade da soja.

MATERIAL E MÉTODOS

A pesquisa foi conduzida em uma área produtora de grãos de aproximadamente 117 ha, localizada no município de Cosmópolis - SP (22º42'S e 47º11'O). Obtivemos os dados de produtividade de grãos secos (13% de umidade) de soja (t/ha) da safra de 2021/22 por meio de monitor de produtividade instalado na colhedora (Figura 1). Testamos 4 maneiras diferentes de limpeza dos dados para reduzir erros ou valores anômalos, sendo elas: Manualmente, utilizando o MapFilter (Maldaner et al. 2021), uma combinação de filtragem manual refino com o MapFilter e utilizando um processo de filtragem automática por meio de inteligência artificial disponível em uma plataforma digital.

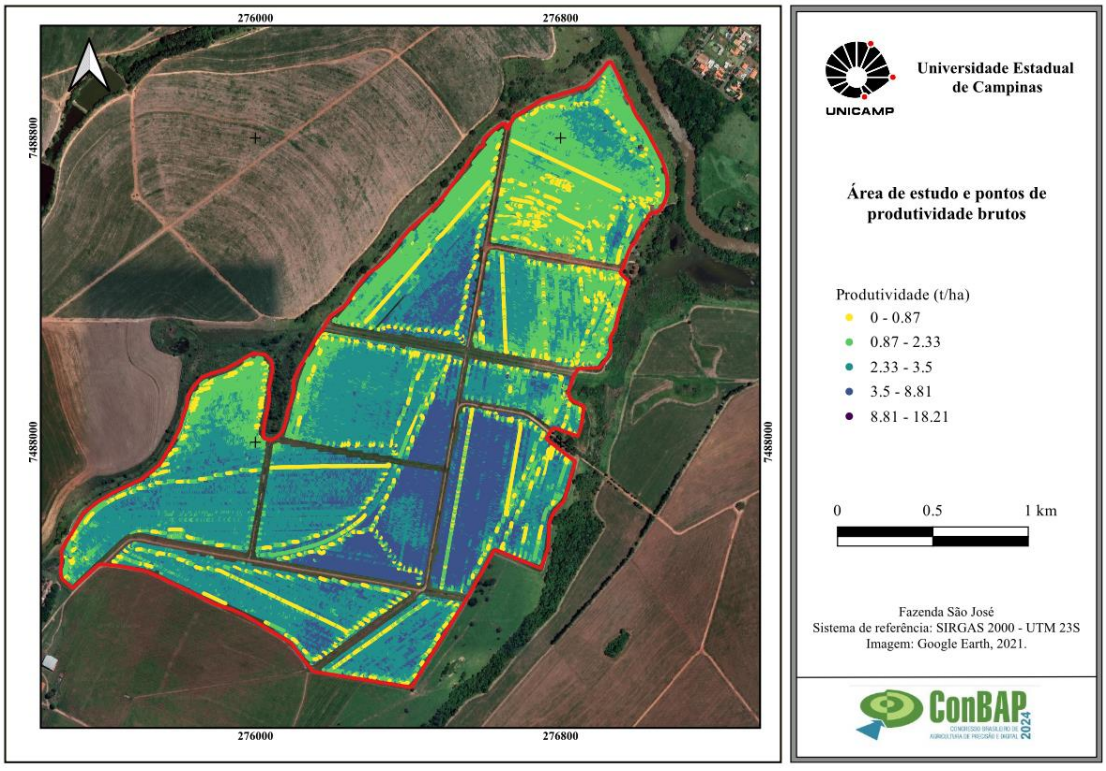


FIGURA 1. Pontos de produtividade brutos de soja ao longo da área de estudo

A filtragem manual consistiu inicialmente em analisar parâmetros da tabela de atributos do monitor de produtividade, identificando aqueles pontos que tinham comportamento diferente do esperado e incoerentes quando comparados com os outros da safra (por meio de histogramas). A filtragem se iniciou com: valores de umidade de grãos discrepantes (abaixo de 10% ou acima de 30%), produtividade (valores muito próximos a 0 ou muito altos para a cultura da soja) e largura de

plataforma parcial. Além disso, foi feita uma filtragem local considerando os pontos próximos, sendo identificadas e removidas as manobras da colhedora e extremos das "linhas mortas", dados fora da área de estudos, valores muito discrepantes a seus vizinhos, bordadura dos talhões, pontos nos carreadores e comportamento atípico da distância entre os pontos (pontos muito próximos entre si, indicando alguma particularidade da colheita, como embuchamento).

O software MapFilter analisa de forma global os dados, levando em consideração valores da vizinhança numa análise isotrópica e anisotrópica. (Maldaner et al., 2021). Nesse caso, testando diferentes configurações de XX e YY, chegamos a conclusão empírica que as configurações a serem usadas nos dados em questão eram no filtro geral 85% Variation of limit, já no filtro local foram 20 metros Spacial dependence e 18% de limite de Variation of limit.

Os dados de sensoriamento remoto foram compostos por 3 índices de vegetação (tabela 2) calculados a partir de imagem do Sentinel-2 com correção atmosférica de nível 2A. As imagens foram coletadas no pico vegetativo baseado no Índice de Vegetação Melhorado (EVI - Enhanced Vegetation Index (Richetti et al. 2018), isto é, imagem do dia 23/02/2024. Buscamos utilizar índices com características distintas, de forma a integrar mais informação nos modelos preditivos (Amaral et. al., 2023).

TABELA 2. Índices de Vegetação calculados.

	Índice de Vegetação	Grupo	Equação
EVI	Enhanced vegetation index	Inclinação	2.5(NIR ? R) / (NIR + 6R ? 7.5B + 1)
SFDVI	Spectral Feature Depth Vegetation Index	Profundidade	[(NIR+G)/2] -[(R+RE)/2]
TCG	Tasseled Cap Transformation Greenness	Eixos Ortogonais	(0.6633NIR)+(0.0087SW1)+(- 0.2856SW2)

Após a limpeza dos dados utilizando os quatro métodos distintos e os dados brutos, optamos por selecionar o método que resultou na menor quantidade de pontos e, em seguida, aleatoriamente escolhemos 5 mil pontos desse conjunto, os quais foram retirados dos conjuntos , a fim de utilizá-los como pontos de validação para as predições.. Dos pontos restantes, escolhemos aleatoriamente 10 mil pontos (devido à viabilidade computacional) em cada conjunto para a etapa de treinamento dos modelos utilizando o algoritmo Random Forest (RF). Os hiperparâmetros do modelo foram otimizados utilizando o método de otimização Bayesiana. Dessa forma, foram criados 5 modelos, cada um calibrado com os dados de um dos 4 métodos de filtragem, além da predição com os dados brutos para fins de comparação. Os modelos gerados foram aplicados aos 5 mil pontos de validação para avaliar o desempenho de cada um. Ainda, também buscando avaliar a efetividade dos métodos de limpeza, modelamos semivariogramas para cada conjunto de filtragem, o que permitiu inferir se a exclusão de pontos realizada aumentou a dependência espacial observada para os dados de produtividade, o que é pré-requisito básico para uma boa inferência da variabilidade presente na área.

RESULTADOS E DISCUSSÃO

Em relação a limpeza de dados, a plataforma digital é que resultou em maiores diferenças (Figura 2), reduzindo o valor médio e a amplitude dos desvios; já os outros 3 métodos apresentaram uma distribuição bastante semelhante. Contudo, avaliando a dependência espacial por meio da modelagem semi variográfica (Tabela 2), é possível notar que o conjunto de dados filtrado pela plataforma digital realmente contrasta dos demais, mas demonstrando que embora tenho reduzido a variabilidade (menor patamar e menor RMSE), a quantificação da dependência espacial foi prejudicada (menor DE e menor alcance). Quando avaliado o desempenho dos modelos de RF (Figura 3), fica evidente que essa filtragem mais intensa prejudicou a modelagem, já que o r2 foi bastante inferior.

Já com relação aos outros três métodos de filtragem, os resultados formam mais equiparáveis, embora quando o MapFilter foi usado, com ou sem um refino manual, os resultados foram melhores: apresentou maior dependência espacial, melhor resultado da validação cruzada da interpolação e melhor desempenho nas predições via sensoriamento remoto. Ademais, observando os boxplots, é possível notar que quando a filtragem manual foi empregada junto com o MapFilter, houve redução da amplitude dos dados, o que parece não ter sido interessante, talvez por limpeza excessiva, retirando regiões de interesse, já que a modelagem variográfica apresentou resultados ligeiramente inferiores, assim como a modelagem por RF. Desse modo, quando as configurações do MapFilter foram bem ajustadas aos dados em análise, seu resultado é suficiente para a limpeza de dados de produtividade de soja, além de ser um processo mais simples e rápido de ser efetuado em comparação à limpeza manual.

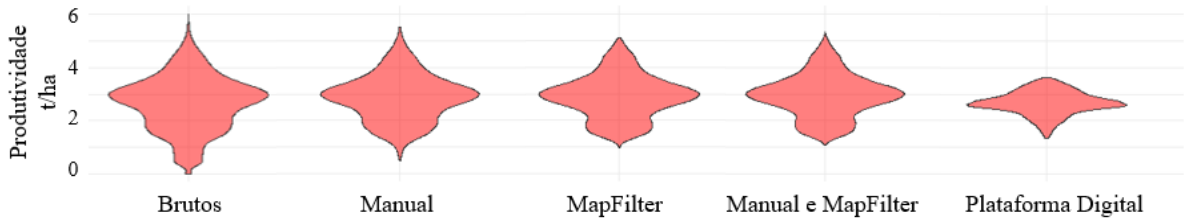


FIGURA 2. Boxplot da distribuição dos dados brutos e após aplicado os métodos de limpeza.

TABELA 2. Parâmetros dos semivariogramas (a: alcance - m, c0: efeito pepita, c1: contribuição, c0+c1: patamar, DE: dependência espacial - c1/patamar) e da validação cruzada do modelo exponencial (r2: coeficiente de determinação e RMSE: raiz quadrada do erro quadrático médio entre predito e observado - t ha-1) para cada conjunto de dados.

Conjunto	a	c0	c1	c0+c1	DE	r2	RMSE
Bruto	128	0,465	0,473	0,938	0,50	0,496	0,770
Manual	159	0,099	0,468	0,567	0,83	0,880	0,300
MapFilter	158	0,031	0,456	0,487	0,94	0,920	0,226
Manual+MF	155	0,031	0,433	0,464	0,93	0,916	0,228
Plataforma	54	0,049	0,126	0,175	0,72	0,940	0,101

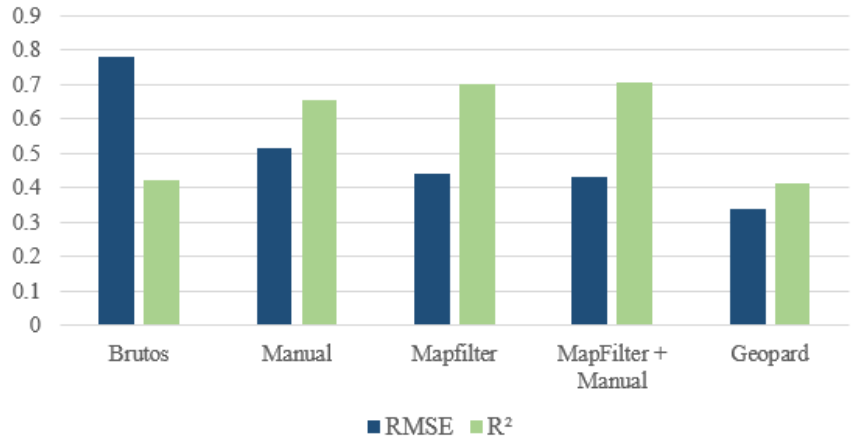


FIGURA 3. Desempenho dos modelos de predição por Randon Forest em função dométodo de filtragem dos dados de produtividade.

CONCLUSÃO

O método de filtragem influência no ajuste dos modelos de predição por sensoriamento remoto. O uso do MapFilter, além de utilização simplificada, elimina de forma eficiente os problemas presentes nos dados de produtividade de soja oriundo de monitor de colheita e pode ser preferido em relação aos outros métodos testados.

AGRADECIMENTOS

Agradecemos o apoio da Fazenda São José pela disponibilização da área de estudo e os dados de produtividade, além do apoio financeiro da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, e da FAPESP, processo n° 2022/03160-8.

REFERÊNCIAS

AMARAL, LUCAS RIOS DO; OLDONI, H.; BAPTISTA, G. M. M.; FERREIRA, G. H. S.; FREITAS, R. G. Vegetation indices from Sentinel-2 and PlanetScope imagery and their relationship with soybean yield. XVI Erupean Conference on Precision Agriculture. Bologna, Italy. 2023

MALDANER, Leonardo Felipe; MOLIN, José Paulo; SPEKKEN, Mark. Methodology to filter out outliers in high spatial density data to improve maps reliability. Scientia Agricola, v. 79, p. e20200178, 2021.

MENEGATTI, Leonardo AA; MOLIN, José P. Remoção de erros em mapas de produtividade via filtragem de dados brutos. Revista Brasileira de Engenharia Agrícola e Ambiental, v. 8, p. 126-134, 2004.

MOLIN, J. P.; AMARAL, L. R.; COLAÇO, A. F. Agricultura de precisão. 1. ed. São Paulo: Oficina de textos, 2015.

FENOTIPAGEM DE ALTO RENDIMENTO PARA ESTIMATIVA DE BIOMASSA DE TRIGO PARA PASTEJO USANDO VEÍCULO AÉREO NÃO TRIPULADO E MACHINE LEARNING

Luiza Rathke [1]; Charleston dos Santos Lima [3]; Diego Maciel Trevisan [4]; Ernandes Manfroi [5]; Christian Bredemeier [2]

[1]Mestranda. Av. Bento Gonçalves, 7712, 91540-000, Porto Alegre/RS, Brasil. Universidade Federal do Rio Grande do Sul; [2]Professor. Av. Bento Gonçalves, 7712, 91540-000, Porto Alegre/RS, Brasil. Universidade Federal do Rio Grande do Sul; [3]Doutorando. Av. Bento Gonçalves, 7712, 91540-000, Porto Alegre/RS, Brasil. Universidade Federal do Rio Grande do Sul; [4]Supervisor de Pesquisa. Estrada do Trigo, 1000, Cx. Postal 3100, 99050-970, Passo Fundo/RS, Brasil. Biotrigo Genética; [5]Gerente de Melhoramento. Estrada do Trigo, 1000, Cx. Postal 3100, 99050-970, Passo Fundo/RS, Brasil. Biotrigo Genética

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A fenotipagem de alto rendimento, utilizando tecnologias avançadas de sensoriamento remoto, como Veículos Aéreos Não Tripulados (VANTs), mostra-se promissora para o melhoramento genético do trigo destinado ao pastejo. Este estudo teve como objetivo estabelecer uma metodologia eficaz para estimar a biomassa do trigo destinado ao pastejo, empregando sensores RGB e multiespectrais acoplados em VANTs. Os experimentos foram realizados em 2022 e 2023 em Passo Fundo/RS com diferentes genótipos de trigo para pastejo. Foram utilizadas variáveis extraídas das imagens, incluindo índices de vegetação, altura estimada das plantas e cobertura foliar. O crescimento dos genótipos de trigo também foi avaliado por sensor proximal de NDVI. Os algoritmos de *machine learnig* avaliados foram: *random forest*, mínimos quadrados parciais (PLS), máquina de vetores de suporte e regressão linear multivariada. O modelo PLS destacou-se como o mais eficaz na previsão da massa verde do trigo destinado ao pastejo, alcançando um R^2 de 0,71 considerando apenas os dados de 2022 e 0,48 quando os dados dos dois anos foram combinados. Estes resultados foram obtidos ao empregar as três variáveis - índices de vegetação, altura de planta e cobertura foliar -, revelando-se mais eficaz do que o uso exclusivo dos índices de vegetação.

PALAVRAS-CHAVE: VANT; NDVI; SENSORIAMENTO REMOTO

ABSTRACT

High-throughput phenotyping, using advanced remote sensing technologies such as Unmanned Aerial Vehicles (UAVs), shows promise for genetic improvement of wheat intended for grazing. This study aimed to establish an effective methodology to estimate the biomass of grazing wheat, employing RGB and multispectral sensors coupled with UAVs. Experiments were conducted in 2022 and 2023 in Passo Fundo with different wheat genotypes for grazing. Variables extracted from the images, including vegetation indices, estimated plant height, and leaf cover, were utilized. The growth of wheat genotypes was also assessed by a proximal NDVI sensor. The evaluated machine learning algorithms included random forest, partial least squares (PLS), support vector machine, and multivariate linear regression. The PLS model stood out as the most effective in predicting the green mass of grazing wheat, achieving an R^2 of 0.71 considering only the 2022 data and 0.48 when data from both years were combined. These results were obtained by employing all three variables - vegetation indices, plant height, and leaf cover - proving more effective than solely using vegetation indices.

KEYWORDS: ;;

INTRODUÇÃO

A cultura do trigo vem se destacando como alternativa para produção de pastagem de inverno devido à carência de forragem entre o outono e o início do inverno no sul do Brasil. Para este fim, programas de melhoramento genético têm demonstrado interesse em desenvolver cultivares que atendam a este nicho. Entre as principais características buscadas nos genótipos está a elevada produção de biomassa da parte aérea, à qual está relacionada com a estatura da planta e índices de vegetação (JIMENEZ-BERNI *et al*., 2018, MEINERZ *et al*., 2012). A fenotipagem de alto rendimento surge como uma abordagem promissora no melhoramento genético do trigo, utilizando tecnologias avançadas como o sensoriamento remoto para coletar dados fenotípicos de forma precisa, eficiente e em larga escala. Essa técnica permite aos melhoristas identificar e selecionar genótipos com características desejáveis de forma mais rápida e eficiente, acelerando assim o processo de melhoramento de plantas (YANG *el al*., 2020; REYNOLDS *et al*., 2020; ZHAO *et al*., 2019).

O Veículo Aéreo Não Tripulado (VANT) tem sido a plataforma mais utilizada para a coleta de dados fenotípicos de alto rendimento. Diferentes sensores podem ser acoplados ao VANT, os mais comuns usados no registro da refletância espectral de plantas são os sensores RGB e multiespectrais (MS) (BAZRAFKAN *et al.*, 2023). A refletância é medida através de valores de números digitais que são usados para o cálculo de índices de vegetação (IVs) (YUE *et al.*, 2018; LU *et al*.,2019). Além disso, dados relacionados à fotogrametria também podem ser obtidos pelos mesmos sensores através do processamento da estrutura de movimento (*SfM*), sendo possível gerar modelos digitais de terreno (MDT) e de superfície (MDS) e estimar a altura das plantas (AP). A área de cobertura foliar (CF) pode ser extraída a partir da porcentagem de pixels da planta e também pode ser útil na estimativa da biomassa (VOLPATO *et al*., 2021).

A estimativa da biomassa das culturas pode ser baseada em IVs, AP e CF individualmente, mas pode ser melhorada ao combiná-los, resultando em previsões mais precisas. Modelos de *machine learning* (ML), como *random forest* (RF), mínimos quadrados parciais (PLS) e máquina de vetores de suporte (SVM), têm demonstrado eficácia na previsão da produtividade e biomassa de várias culturas. Esses modelos são particularmente relevantes para a fenotipagem de alto rendimento devido à sua capacidade de lidar com grandes conjuntos de dados e complexidades não lineares (GILL *et al*., 2022).

OBJETIVOS

Este trabalho tem como objetivo estabelecer uma metodologia para obtenção de dados fenotípicos de alto rendimento por SR, avaliar o desenvolvimento de genótipos destinados ao pastejo utilizando NDVI através de sensor proximal e buscar o melhor modelo de ML para estimar a biomassa fresca de genótipos de trigo destinados ao pastejo a partir de IV, AP e CF obtidos por sensores RGB e MS embarcados em VANT.

MATERIAL E MÉTODOS

Os trabalhos de campo foram conduzidos em 2022 e 2023, na área experimental da empresa Biotrigo Genética em Passa Fundo, RS, Brasil. Os experimentos foram compostos por diferentes genótipos de trigo destinados à pastagem. As parcelas foram compostas por 7 linhas de semeadura, com 7 metros de comprimento e espaçamento entrelinhas de 0,17 metros. Para simulação do pastejo foram realizados cortes da biomassa acima de 10 centímetros do solo de cada parcela; o primeiro corte ocorreu aos 40 dias após a semeadura e os próximos cortes a cada 21 dias aproximadamente.

Dados de altura foram coletados antes dos cortes através de medição utilizando régua graduada; e dados de biomassa foram obtidos a partir de amostragem e pesagem da massa verde cortada. As coletas dos dados por VANT foram realizadas em duas datas que antecederam os cortes das parcelas.

Em 2022 as missões de voo foram realizadas antes do 5º e 6º cortes, enquanto que em 2023, antes do 4º e 5º cortes. Para a obtenção das imagens aéreas foram utilizados dois VANTs DJI com sensores embarcados (TABELA 1). Além das imagens, foram coletados dados da reflectância do dossel das parcelas, por meio do NDVI, com o sensor óptico ativo proximal GreenSeeker (GS) em diferentes momentos entre os cortes.

TABELA 1. Detalhes das missões de voo.

Ano	Data do voo	VANT	Sensor
2022	28 de junho	Phantom 4	RGB RGNir (Mapir Survey 3)
	19 de julho	Phantom 4	RGB RGNir (Mapir Survey 3)
2023	30 de maio	Phantom 4 Multiespectral	RGB R, RedEdge e Nir (DJI)
	20 de junho	Phantom 4 Multiespectral	RGB R, RedEdge e Nir (DJI)

As imagens do VANT foram processadas utilizando o software Agisoft PhotoScan Pro. As principais etapas de processamento incluíram alinhamento das imagens, construção da nuvem de pontos densa, geração de ortomosaico e dos modelos digitais de terreno (MDT) e de superfície (MDS) (FIGURA 1).

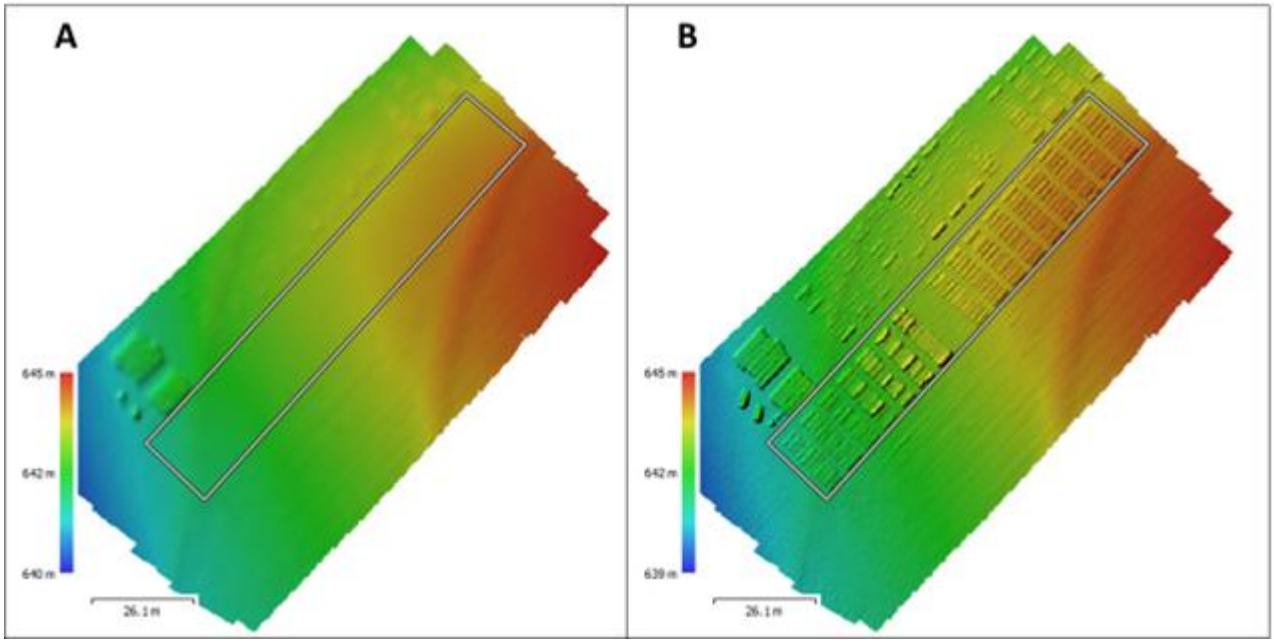


FIGURA 1. A) Modelo digital de terreno e B) modelo digital de superfície do 1º voo de 2022.

Utilizando o software QGIS versão 3.22.8 foi construído o *shapefile* que delimita a área analisada (três linhas centrais) de cada parcela. Todas as informações extraídas correspondem as características do interior da área delimitada pelo *shapefile*. Este estudo utilizou sete IVs (TABELA 2) os quais foram calculados usando o número digital de cada pixel do ortomosaico. Em cada parcela foram extraídos a média de cada IV e das bandas R, G e B.

TABELA 2. Índices de vegetação utilizados.

Índice	Nome	Equação

NDVI	*Normalized Difference Vegetation Index*	$(NIR - R)/(NIR + R)$	Eq. (13)
ExG	*Excess Green Index*	$2g - r - b$	Eq. (14)
GLI	*Green Leaf Index*	$2G - R - B/2G + R + B$	Eq. (15)
VARI	*Visual Atmospheric Resistance Index*	$g - r/g + r - b$	Eq. (16)
GRVI	*Green Red Vegetation Index*	$G - R/G + R$	Eq. (17)
MGRVI	*Modified Green Red Vegetation Index*	$G^2 - R^2/G^2 + R^2$	Eq. (18)
RGBVI	*Red Green Blue Vegetation Index*	$(G^2 - R \times B)/(G^2 - R \times B)$	Eq. (19)

Observação: R, G e B representam o número digital das faixas do vermelho, verde e azul, respectivamente. NIR representa a faixa do infravermelho. r = R/(R+G+B), g = G/(R+G+B), b = B/(R+G+B) (LU *et al*., 2019).

Os dados de cobertura foliar (CF) das plantas da parcela foram extraídos a partir da utilização do IV ExG. Pixels com valores de ExG maiores ou iguais a 0,1 foram considerados como área de cobertura foliar (FIGURA 2C). Para estimar a altura das plantas (AP) da parcela, foram utilizados os modelos digitais de elevação com a subtração do MDS pelo MDT. Foram utilizados apenas os pixels considerados na CF e utilizado a mediana para representar a AP de cada parcela (FIGURA 2D). Os mesmos *shapefiles* usados para extrair os IVs também foram utilizados para extrair os valores da CF e da AP (FIGURA 2A).

RESULTADOS E DISCUSSÃO

Com base na análise descritiva dos dados de altura e massa verde (TABELA 3), pode-se observar que as alturas das plantas de trigo mantiveram-se relativamente estáveis ao longo dos anos e voos de 2022 e 2023, com valores mínimos em torno de 0,26 metros e máximos em aproximadamente 0,40 metros. No entanto, em relação à massa verde, notou-se uma variação mais expressiva, destacando-se uma diferença mais significativa entre os valores máximo e mínimo no ano de 2023.

TABELA 3. Análise descritiva dos dados de massa verde (kg ha^{-1}) e altura (m) coletados manualmente.

	2022 - 1º voo (n = 60)		**2022 - 2º voo (n = 50)**		**2023 - 1º voo (n = 138)**		**2023 - 2º voo (n = 138)**	
	Altura	**M. Verde**	**Altura**	**M. Verde**	**Altura**	**M. Verde**	**Altura**	**M. Verde**
Mínimo	0.26	1585	0,26	2396	0,20	1698	0,25	1245
1º Quart.	0.31	2472	0,33	3415	0,30	3585	0,28	2340
Mediana	0.34	2981	0,35	3834	0,30	4340	0,30	2925
Média	0.34	2930	0,35	3936	0,31	4158	0,30	2933
3º Quart.	0.35	3290	0,37	4398	0,35	4670	0,30	3434
Máximo	0.39	4264	0,43	5962	0,40	5811	0,40	5585

CONCLUSÃO

A fenotipagem de alto rendimento utilizando tecnologias avançadas de sensoriamento remoto, como VANTs, se mostrou uma abordagem promissora para o melhoramento genético do trigo destinado ao pastejo. A metodologia estabelecida permitiu a obtenção de informações precisas e em larga escala sobre o desenvolvimento das plantas ao longo do tempo, destacando-se pela eficiência e escalabilidade em comparação com as técnicas tradicionais de avaliação fenotípica. Ao integrar VANTs, sensoriamento remoto e técnicas de *machine learning*, não apenas acelera-se o processo de seleção de genótipos com características desejáveis, mas também se obtém uma compreensão mais abrangente do comportamento das plantas em diferentes condições ambientais.

Este estudo ressalta a importância da validação e da consideração cuidadosa da qualidade dos dados de sensoriamento remoto para garantir resultados precisos e confiáveis. Além disso, destaca-se a relevância da integração de dados provenientes de diversas fontes, como sensores remotos e instrumentos de campo, para uma análise mais completa do desenvolvimento das plantas e sua relação com a produtividade.

Por fim, os modelos de *machine learning*, notadamente o Mínimos Quadrados Parciais (PLS) combinado com índices de vegetação, altura da planta e cobertura foliar, demonstraram-se altamente eficazes na previsão da biomassa verde do trigo destinado ao pastejo. Esses resultados reforçam a premissa de que a integração de VANTs, sensoriamento remoto e técnicas avançadas de *machine learning* oferece uma abordagem robusta e eficiente para o desenvolvimento e seleção de genótipos de trigo com alta produção de biomassa para pastejo.

AGRADECIMENTOS

Os autores da UFRGS deste trabalho desejam expressar sinceros agradecimentos à Biotrigo Genética pela colaboração e parceria. Agradecemos especialmente pela gentileza em disponibilizar os locais de ensaios do programa de melhoramento de trigo para pastejo, possibilitando a realização deste estudo. Agradecemos também pela hospitalidade e pelas valiosas trocas de ideias ao longo deste trabalho.

REFERÊNCIAS

BAZRAFKAN, A.; DELAVARPOUR, N.; ODUOR, P. G.; BANDILLO, N.; FLORES, P. Na overview of using unmanned aerial system mounted sensors to measure plant above-ground biomass. **Remote sensing**, v.15, n.3543, 2023.

GILL, T.; GILL, S. K.; SAINI, D. K.; CHOPRA, Y.; KOFF, J. P.; SANDHU, K. S. A comprehensive review of high throughput phenotyping and machine learning for plant stress phenotyping. **Phenomics**, v.2, p.156-183, 2022.

GOMES, A. P. A.; QUEIROZ, D. M.; VALENTE, D. S. M.; PINTO, F. A. C.; ROSAS, J. T. F. Comparing a single-sensor câmera with a multisensor câmera for monitoring coffee crop using unmanned aerial vehicles. **Engenharia Agrícola**, v.41, p.87-97, 2021.

JIMENEZ-BERNI, J. A.; DEERY, D. M.; ROZAS-LARRAONDO, P.; CONDON, A. G.; REBETZKE, G. J.; JAMES, R. A.; BOVILL, W. D.; FURBANK, R. T.; SIRAULT, X. R. R. High throughput determination of plant height, ground cover, and above-ground biomass in wheat with LiDAR. **Frontiers in Plant Science**, v.9, n.237, 2018.

LU, N.; ZHOU, J.; HAN, Z.; LI, D.; CAO, Q.; YAO, X.; TIAN, Y.; ZHU, Y.; CAO, W.; CHENG, T. Improved estimation of aboveground biomass in wheat from RGB imagery and point cloud data acquired with a low-cost unmanned aerial vehicle system. **Plant Methods**, v.15, n.17, 2019.

MEINERZ, G. R.; OLIVO, C. J.; FONTANELI, R. S.; AGNOLIN, C. A.; HORST, T.; BEM, C. M. Produtividade de cereais de inverno de duplo propósito na depressão central do Rio Grande do Sul. **Revista Brasileira de Zootecnia**, v.41, n.4, p.873-882, 2012.

RANDELOVIC, P.; DORDEVIC, V., MILADINOVIC, J.; PRODANOVIC, S.; CERAN, M.; VOLLMAN, J. High-throughput phenotyping for non-destructive estimation of soybean fresh biomass using a machine learning model and temporal UAV data. **Plant Methods**, v.19, n.89, 2023.

REYNOLDS, M.; CHAPMAN, S.; CRESPO-HERRERA, L.; MODELO, G.; MONDAL, S.; PEQUENO, D. N. L.; PINTO, F.; PINERA-CHAVEZ, F.; POLAND, J.; RIVERA-AMADO, C.; PIERRE, C. S.; SUKUMARAN, S. Breeder friendly phenotyping. **Plant Science**, v.295, n.110396, 2020.

ROTH. L.; FOSSATI, D.; KRAHENBUHL, P.; WALTER, A.; HUND, A. Image-based phenomic prediction can provide valuable decision support in wheat breeding. **Theoretical and Applied Genetics**, v.136, n.162, 2023.

VOLPATO, L.; PINTO, F.; GONZALÉX-PÉREZ, L.; THOMPSON, I. G.; BORÉM, A.; REYNOLDS, M. GÉRARD, B., MOLERO, G., RODRIGUES, F. A. JR. High throughput field phenotyping for plant height using UAV-based RGB imagery in wheat breeding lines: feasibility and validation. **Frontiers in Plant Science**, v.12, n.591587, 2021.

YANG, W.; FENG, H.; ZHANG, X.; ZHANG, J.; DOONAN, J. H.; BATCHELOR, W. D.; XIONG, L.; YAN, J. Crop phenomics and high-throughput phenotyping: past decades, current challenges and future perspectives. **Molecular Plant**, v.13, p.187-214, 2020.

YUE, J.; FENG, H.; YANG, G.; LI, Z. A comparison of regression techniques for estimation of above-ground winter wheat biomass using near-surface spectroscopy. **Remote Sensing**, v.10, n.66, 2018.

ZHAO, C.; ZHANG, Y.; DU, J.; GUO, X.; WEN, W.; GU, S.; WANG, J.; FAN, J. Crop phenomics: current status and perspectives. **Frontiers in Plant Science**, v.10, n.714, 2019.

PREDIÇÃO DE CARBONO ORGÂNICO DO SOLO UTILIZANDO BIBLIOTECAS ESPECTRAIS DE SENSORES XRF E VIS-NIR: UMA ANÁLISE COMPARATIVA DO DESEMPENHO INDIVIDUAL E COMBINADO DOS SENSORES

Tiago Rodrigues Tavares [1]; Marcos Mantelli Ragagnin [2]; Budiman Minasny [5]; Hudson Wallace Pereira de Carvalho [4]; José Lavres [3]

[1]Pesquisador Pós-doc. Av. Centenário, 303 - São Dimas, Piracicaba - SP, Brasil. Centro de Energia Nuclear na Agricultura (CENA), Universidade de São Paulo (USP); [2]Graduando. Av. Pádua Dias, 11, Piracicaba - SP, Brasil. Escola Superior de Agricultura Luiz de Queiroz (ESALQ), Universidade de São Paulo (USP); [3]Professor. Av. Centenário, 303 - São Dimas, Piracicaba - SP, Brasil. Centro de Energia Nuclear na Agricultura (CENA), Universidade de São Paulo (USP); [4]Professor. Benguerir, Marrocos. University Mohammed VI Polytechnic; [5]Professor. 1 Central Avenue, South Eveleigh, Sydney, NSW, Australia . Sydney Institute of Agriculture, The University of Sydney

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Esse estudo utiliza uma biblioteca espectral (n = 3441 amostras) de dados de sensores vis-NIR e XRF para comparar o desempenho destas técnicas usadas individualmente e de forma combinada para a predição de carbono orgânico do solo (SOC). Embora se saiba que o vis-NIR é capaz de detectar componentes da matéria orgânica dos solos, nossa hipótese é que a inclusão de componentes minerais do XRF melhorará a previsão do SOC para solos tropicais do Brasil. Este artigo tem como objetivo avaliar o ganho preditivo que a fusão de dados apresenta em cenários usando modelos locais (com PLS) e modelos globais (usando modelos cubistas). Os resultados mostraram que a modelagem local teve, em geral, um RMSE menor do que os modelos cubistas em todos os cenários de sensores. Em média, os modelos cubistas que utilizam apenas sensores vis-NIR apresentaram um RMSE 50% maior em comparação com os modelos locais, enquanto os modelos que incorporam apenas dados de XRF apresentaram RMSE 67% maior, e os que integram dados de vis-NIR e XRF apresentaram um RMSE 36% maior quando aplicados à biblioteca nacional, em comparação com os modelos locais. Com relação ao uso individual e combinado dos sensores, os modelos locais obtiveram um RMSE de 1,80 g kg^{-1} usando apenas vis-NIR, 1,82 g kg^{-1} usando apenas XRF e 1,54 g kg^{-1} para vis-NIR+XRF. Assim, o uso combinado mostrou uma redução de RMSE de 15 e 16% em comparação com o uso individual do vis-NIR e do XRF, respectivamente. Da mesma forma, os modelos cubistas mostraram um RMSE de 2,70 g kg^{-1} apenas com o vis-NIR, 3,04 g kg^{-1} usando apenas o XRF e 2,09 g kg^{-1} com a fusão espectral. Isso representa uma redução de RMSE de 23 e 31% em comparação com o uso individual do vis-NIR e do XRF, respectivamente. Esses resultados fornecem informações valiosas para esclarecem o potencial que sensores vis-NIR e XRF tem para predição de SOC em solos tropicais brasileiros.

PALAVRAS-CHAVE: sensores inteligentes; sequestro de carbono no solo; sensoriamento próximo do solo

ABSTRACT

This study uses a spectral library (n = 3441 samples) of vis-NIR and XRF sensor data to compare the performance of these techniques when used individually and in combination for predicting soil organic carbon (SOC). While vis-NIR is known to be able to detect organic matter components of soils, we hypothesize that the inclusion of mineral components from XRF will enhance the prediction of SOC for tropics soils of Brazil. This paper aims to assess the predictive gain that data fusion presents in scenarios using local models (with PLS) and global models (using cubist models). The results showed that local modeling in general had a lower RMSE than cubist models in all scenarios of sensors use. On average, cubist models utilizing only vis-NIR sensors exhibited a 50% higher Root Mean Square Error (RMSE) compared to local models, whereas models incorporating only XRF data

showed a 67% higher RMSE, and those integrating both vis-NIR and XRF data demonstrated a 36% higher RMSE when applied to the national library, as opposed to local models. Regarding the individual and combined use of the sensorslocal models achieved an RMSE of 1.80 g kg^{-1} using only vis-NIR, 1.82 g kg^{-1} using only XRF and 1.54 g kg^{-1} for vis-NIR+XRF. Hence, the combined use showed an RMSE reduction of 15 and 16% compared to the standalone use of vis-NIR and XRF, respectively. Similarly, cubist models showed an RMSE of 2.70 g kg^{-1} with the vis-NIR alone, 3.04 g kg^{-1} using only the XRF, and 2.09 g kg^{-1} for the spectral fusion. This represents an RMSE reduction of 23 and 31% compared to the standalone use of vis-NIR and XRF, respectively. These results provide valuable information to clarify the potential that vis-NIR and XRF sensors have for predicting SOC in Brazilian tropical soils.

KEYWORDS: ;

INTRODUÇÃO

There is consensus on the potential of using diffuse reflectance spectroscopy in the visible and near infrared (vis-NIR) to estimate soil organic carbon (SOC) due to their close association with the soil's organic components (Ben-Dor, 2002). Spectral libraries of vis-NIR sensors with different regional coverage, together with advanced predictive modeling techniques (e.g. cubist models), have recently been explored to optimize the analytical performance of such technique for the determination of SOC (Cezar et al., 2019; Ng et al., 2022; Padarian et al., 2019).

On the other hand, the suggestion that SOC can be predicted using XRF spectra is also suggested, such as by Morona et al. (2017). Although X-ray fluorescence (XRF) spectra do not usually show emission lines for H, C and O, i.e. elements present in organic compounds, the scattering energy of the X-rays that hit the sample is inversely proportional to the average atomic number of the sample (Y?lmaz and Boyda?, 2018). In other words, there is a theoretical rationale for the relationship between low atomic number elements and XRF spectra. Furthermore, in a different study, direct relationships were also observed between Fe and Ti emission lines and SOC contents. Fe and Ti emission lines are variables commonly seen as important in clay models (Tavares et al., 2020a) and, in turn, clay is directly related to SOC concentration.

Although studies have shown promising performances for predicting SOC using XRF ($R^2 \geq 0.61$), they involve local or regional databases. Thus, it is not known whether these models are scalable. More recently, a study in China evaluated the combined spectra of XRF and vis-NIR to estimate soil organic matter (SOM), showing that the fusion of data between these sensors can improve predictions by up to 16% (Shi et al., 2023), reducing the RMSE from 2.41 g kg^{-1}, using only vis-NIR, to 2.08 g kg^{-1}, using vis-NIR+XRF (the values of SOM published by the above mentioned authors were converted, dividing by 1.724, and expressed in SOC in the present paper).

OBJETIVOS

Given this scenario, this study aims to answer the following two questions, which comprise the state-of-the-art proximal soil sensing using XRF and vis-NIR sensors:

- Considering the use of vis-NIR and XRF sensors individually and combined via spectral concatenation, what is the best scenario for predicting organic carbon in tropical soils?
- What would be the performance loss of predictive models using national spectral libraries instead of local ones in Brazilian tropical soils?

MATERIAL E MÉTODOS

This study used a national spectral library (n = 3441 samples) and nine local spectral libraries (n > 84 samples) to evaluate the performance of models for predicting SOC in local samples. The spatial distribution of the national spectral library samples and the locality of the local libraries are shown in Figure 1. Local libraries were selected at different latitudes in Brazil to represent a wide range of national soils when validating the models. All samples were analyzed using vis-NIR and XRF sensors, and the reference content of SOC were determined via oxidation with potassium dichromate (Walkley and Black, 1934). XRF spectra were obtained with a portable equipment, model S1 Titan (Bruker AXS, Madison, USA), using instrumental conditions suggested by Tavares et al. (2020b). Vis-NIR spectra with spectral range from 350 to 2500 nm (resolution < 8 nm) were obtained using the SM-3500 equipment (Spectral Evolution, Madison, USA). The samples from each of the local libraries were divided into two sets, a calibration set with 70% of the data and a validation set with the remaining 30% of the data. The division was carried out by applying the Kennard-Stone algorithm to the SOC data. Models using partial least squares (PLS) regression were fit using the calibration set of the local libraries. While Cubist models were used to calibrate predictive models with data from the national spectral library (Minasny and McBratney, 2008), PLS models were used to calibrate local models. For comparison of both modeling scenarios (i.e., local vs. national), the models were extrapolated to the validation sets of the nine local libraries. All models were evaluated for the following scenarios: (i) using only vis-NIR data, (ii) using only XRF data and (iii) with the spectra of both sensors combined (vis-NIR+XRF). The quality of models was assessed by the coefficient of determination (R^2), the root mean square error (RMSE), and the ratio of performance to interquartile range (RPIQ). The RPIQ was calculated by dividing the interquartile range of the SOC reference values from each validation set by the RMSE of each prediction.

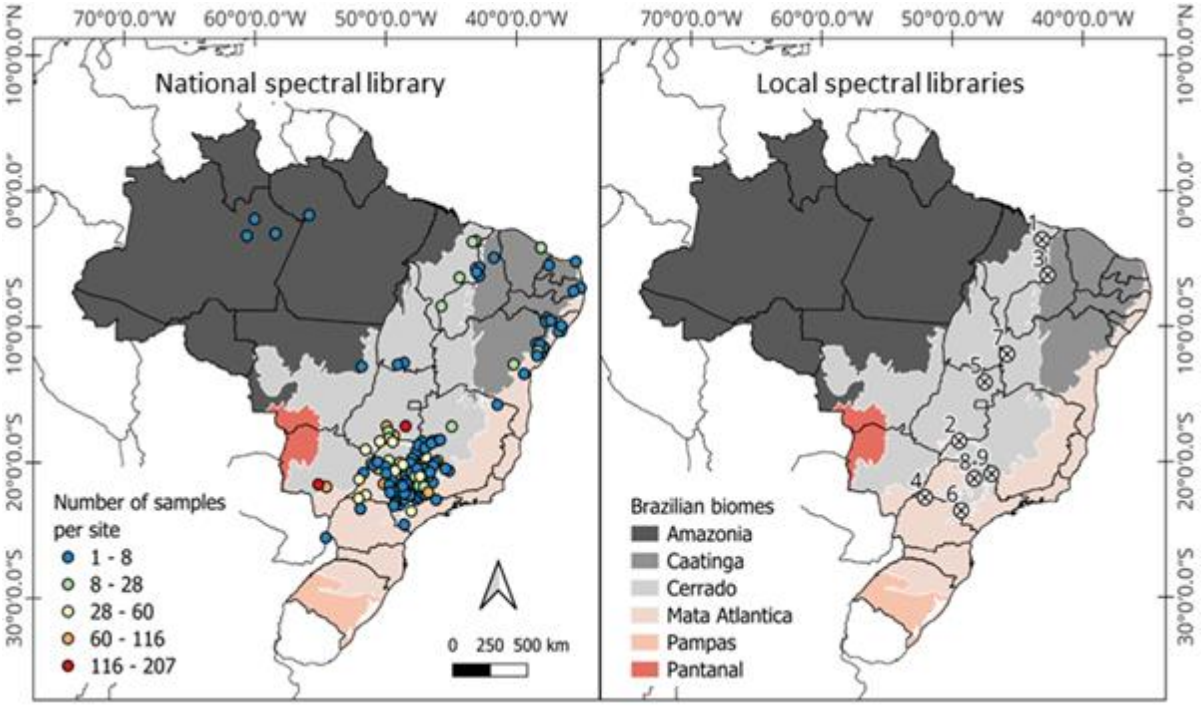


FIGURE 1. Spatial distribution of samples from the national spectral library (left) and location of the nine local spectral libraries (right). Local libraries 1, 2, 3, 4, 5, 6, 7, 8 and 9 are respectively located in the municipalities of Mata Roma-MA, Cachoeira Dourada-GO, Regeneração-PI, Paranapoema-PR, Alto Paraiso de Goiás-GO, Coronel Macedo-SP, Luís Eduardo Magalhães-BA, Jaboticabal-SP and São Sebastião do Paraíso-MG. **Distribuição espacial das amostras que compreendem a biblioteca espectral nacional (esquerda) e localidade das nove bibliotecas locais situadas em diferentes latitudes do território brasileiro (direita). As bibliotecas locais 1, 2, 3, 4, 5, 6, 7, 8 e 9 estão respectivamente localizadas nos municipios de Mata Roma-MA, Cachoeira**

Dourada-GO, Regeneração-PI, Paranapoema-PR, Alto Paraiso de Goiás-GO, Coronel Macedo-SP, Luís Eduardo Magalhães-BA, Jaboticabal-SP e São Sebastião do Paraíso-MG.

RESULTADOS E DISCUSSÃO

The national spectral library used has 3441 samples, with SOC content ranging from 1.16 to 35.47 g kg^{-1}. A total of 90% of the samples have a content of less than 19.14 g kg^{-1}, meaning that predictions of samples above this value may present a greater error due to the smaller amount of data for training the model. Regarding the validation set of local libraries, the local libraries 9, 5 and 3 have the widest range of SOC contents with minimum and maximum values oscillating between 6.97-26.16, 10.47-2.16 and 9.30-23.84 g kg^{-1}, respectively. The sets with the lowest ranges are libraries 4 and 7, with values varying between 5.81-8.72 and 5.24-9.88 g kg^{-1}, respectively. Overall, the average values of the validation sets range from 6.96 g kg^{-1} (for library 7) to 18.11 g kg^{-1} (for library 3). This diversity in SOC content reflects the geographical diversity of the local sets (Figure 1). Validation sets at different latitudes in Brazil were chosen to evaluate the spectral library models in order to make the analyses more robust. Of these nine local databases, seven are in the Cerrado biome (local libraries 1, 2, 5, 7, 8 and 9), two are in the Atlantic Forest biome (4 and 6) and one is located in the Caatinga biome (local library 3). With regard to climate classification, local libraries 1, 2, 3, 4, 5 and 7 are in a tropical savannah climate (Aw), while library 6 is in a humid subtropical climate without a dry season (Cfa), library 8 is in a humid subtropical climate with a dry winter (Cwa) and library 9 is in a subtropical highland climate (Cwb). The boxplot of the SOC content of each spectral library and calibration and validation set is shown in Figure 2.

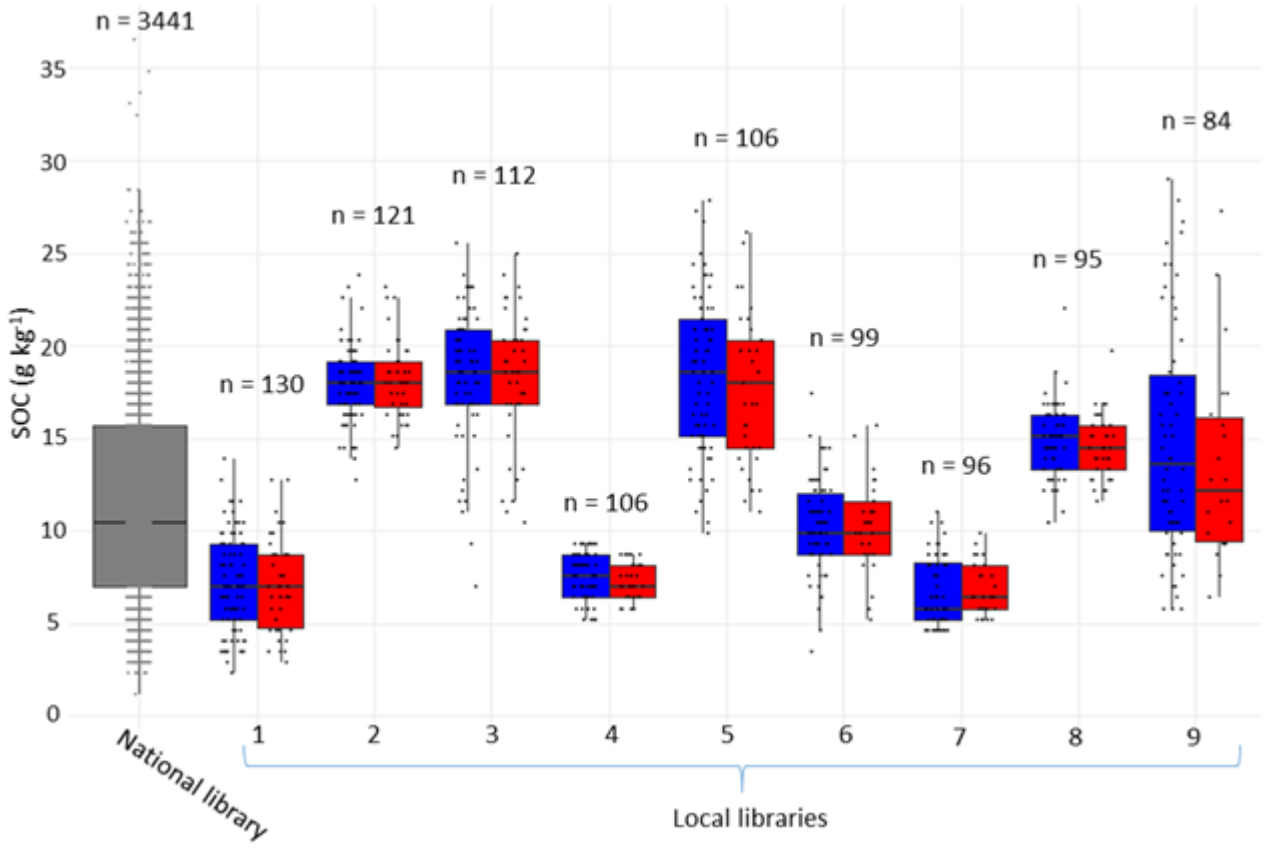


FIGURE 2. Boxplot of the soil organic carbon (COS) content of the samples from the national spectral library (in gray) and the calibration (in blue) and validation (in red) sets from the nine local libraries. **Gráficos de boxplot do teor e carbono orgânico do solo (COS) das amostras da biblioteca espectral nacional (em cinza) e dos conjuntos de calibração (em azul) e validação (em vermelho) das nove bibliotecas locais.**

The results of this study show that local modeling had a lower RMSE than cubist models in all scenarios of sensors (Table 1). With exceptions only for local library 8 for vis-NIR data (with a 14% reduction in the RMSE of the cubist model compared to the local one), local library 7 for XRF data (with a 5% reduction in the RMSE), and libraries 2 and 6 when using vis-NIR+XRF data (with respective reductions of 13 and 1% in the RMSE of the cubist model compared to the local one). On average, cubist models with vis-NIR sensors had a 50% higher RMSE than local models, while models with XRF data were 67% higher on average and models with vis-NIR+XRF data were 36% higher when using cubist models and national libraries compared to PLS models with local libraries (Table 1). Local models have performed better than models with national spectral libraries, especially when local databases have enough samples so that the model can capture local relationships (Guerrero et al., 2014; Padarian et al., 2019).

TABLE 1. Bias, RMSE, maximum error, percentile 95% of the error (i.e. maximum error for 95% of the samples in the validation set) and the ratio of performance to interquartile range (RPIQ) obtained for SOC prediction in each of the nine validation sets for vis-NIR, XRF and vis-NIR+XRF data for the PLS models (in the local libraries) and the cubist models (in the national library). Along with the information on the RMSE for the cubist models, the increase (with a positive sign) or decrease (with a negative sign) of its value in relation to the RMSE of the local model was presented. **Bias, RMSE, erro máximo, percentil 95% do erro (i.e., erro máximo de 95% das amostras do conjunto de validação) e do desempenho da razão entre o desempenho e a distância interquartil (RPIQ) obtida para predição de SOC em cada um dos nove conjuntos de validação para os dados vis-NIR, XRF e vis-NIR+XRF e usando modelos PLS, nas bibliotecas locais, e cubista, na biblioteca nacional. Junto a informação do RMSE dos modelos cubistas, foi apresentado o aumento (com sinal positivo) ou diminuição (com sinal negativo) do seu valor em relação ao RMSE do modelo local.**

Local libraries	Bias		RMSE		Error max.		Error 95%		RPIQ	
	Local	Cubist	Local	Cubist	Local	Cubist	Local	Cubist	Local	Cubist
vis-NIR										
1	-0.17	0.18	**1.05**	1.17 (+11%)	2.84	**2.78**	**1.83**	2.12	3.61	3.21
2	-0.17	0.45	**1.72**	1.80 (+5%)	**4.28**	4.43	3.20	**3.07**	1.35	1.29
3	0.61	-5.07	**2.75**	6.31 (+129%)	**7.72**	16.43	**6.12**	10.36	1.27	0.55
4	0.21	0.35	**0.77**	0.99 (+29%)	**1.35**	2.81	**1.29**	1.99	1.89	1.47
5	0.09	-1.77	**2.02**	3.46 (+71%)	**4.29**	7.79	**3.97**	5.90	2.94	1.72
6	-0.36	1.62	**2.22**	2.81 (+27%)	**4.20**	6.04	**3.76**	5.39	1.04	0.82
7	0.02	1.90	**0.87**	2.60 (+199%)	**2.00**	7.79	**1.68**	3.86	3.33	1.12
8	0.11	0.14	1.99	**1.71** (-14%)	4.10	**3.85**	3.77	**3.47**	1.16	1.35
9	-0.14	-1.31	**2.80**	3.45 (+23%)	8.81	**7.09**	**4.66**	6.63	2.48	2.02
Mean	–	–	**1.80**	2.70 (+50%)	**4.40**	6.56	**3.36**	4.76	–	–
XRF										
1	-0.37	2.09	**1.38**	3.11 (+125%)	**3.57**	8.16	**2.54**	5.51	2.73	1.21
2	0.03	0.45	**1.8**	2.25 (+25%)	**3.93**	4.41	**3.41**	3.78	1.29	1.03
3	0.8	-3.71	**2.79**	5.07 (+82%)	**6.98**	11.02	**5.41**	8.87	1.25	0.69
4	0.01	-0.61	**0.85**	1.13 (+33%)	**1.63**	2.36	**1.43**	1.93	1.70	1.29
5	-0.21	-4.13	**1.84**	5.66 (+208%)	**4.71**	10.99	**3.96**	10.26	3.24	1.05
6	0.06	0.48	**1.97**	2.14 (+9%)	**4.61**	6.41	**3.84**	3.85	1.18	1.09
7	-0.22	0.16	1.46	**1.39** (-5%)	5.54	**3.01**	**2.51**	2.87	1.98	2.09
8	0.12	2.33	**1.68**	3.04 (+81%)	**3.58**	5.80	**2.97**	5.66	1.38	0.76
9	-0.11	-1.52	**2.61**	3.56 (+36%)	**5.07**	7.31	**4.65**	6.50	2.67	1.96
Mean	–	–	**1.82**	3.04 (+67%)	**4.40**	6.61	**3.41**	5.47	–	–
vis-NIR+XRF										
1	0.04	2.48	**0.96**	2.70 (+181%)	**2.09**	5.90	**1.93**	3.71	3.92	1.40
2	0.00	1.00	1.84	**1.60** (-13%)	4.08	**3.94**	3.93	**2.74**	1.26	1.45
3	0.66	-1.38	**2.19**	3.37 (+54%)	**5.67**	8.60	**4.11**	7.16	1.59	1.03
4	0.07	-0.40	**0.73**	0.95 (+30%)	**1.82**	2.48	**1.19**	1.80	1.98	1.52
5	0.43	-1.30	**1.59**	2.75 (+73%)	**3.67**	8.57	**3.15**	5.74	3.73	2.16
6	-0.27	0.75	1.64	**1.63** (-1%)	4.41	**3.29**	3.33	**3.01**	1.42	1.42
7	-0.11	1.14	**0.82**	1.47 (+79%)	**1.97**	2.59	**1.65**	2.44	3.55	1.98
8	-0.16	0.48	**1.49**	1.54 (+3%)	**3.06**	3.09	2.96	**2.79**	1.56	1.50
9	-0.88	-1.86	**2.58**	2.82 (+9%)	**5.51**	6.73	**4.48**	5.95	2.70	2.47
Mean	–	–	**1.54**	2.09 (+36%)	**3.59**	5.02	**2.97**	3.93	–	–

In general, both the local models and the models with the spectral library performed better with the combination of sensors than with the sensors used individually (Table 2). In the local modeling, only one area (local library 2) showed better predictive performance using the vis-NIR sensor alone, while using the national spectral library, only two areas (local library 1 and 7) showed better performance with individual sensors. When analyzing the average RMSE for the predictions using local models (Table 2), combined spectra (vis-NIR+XRF) had an error reduction of 15% in relation to the individual error of vis-NIR and a 16% reduction in relation to XRF (RMSE of vis-NIR was 1.80 g kg^{-1}, of XRF 1.82 g kg^{-1} and of fusion 1.54 g kg^{-1}). Compared to the cubist model, vis-NIR+XRF models showed a reduction of 23% compared to vis-NIR and 31% compared to XRF (RMSE for vis-NIR was 2.70 g kg^{-1}, for XRF 3.04 g kg^{-1} and for fusion 2.09 g kg^{-1}). Data fusion was more advantageous for the national spectral library model than for the local models, possibly due to the increased level of complexity of generalist models with large databases, which need more complex levels of information as input. When comparing the results of the models involving the national spectral library with those obtained by Shi et al., (2023) - the only scientific study to have evaluated data fusion between vis-NIR and XRF for SOC prediction to date -, we observed in the present study that the performance gain of fusion compared to vis-NIR (23%) was slightly higher than that achieved by the authors (16%). However, the RMSE observed by both was very similar (RMSE of 2.09 g kg^{-1} for Brazilian soils and 2.08 g kg^{-1} for Chinese soils).

TABLE 2. Comparison of the predictive performance of models calibrated using only vis-NIR and XRF sensors, and using combined sensors (vis-NIR+XRF). The performances were presented for the PLS models applied to local libraries and for the cubist model applied to national library. The reduction or increase in RMSE (RI%) in relation to the individual performance of the vis-NIR sensor and in relation to that of the XRF sensor were also presented. **Comparação do desempenho preditivo de modelos calibrados usando apenas sensores vis-NIR e XRF, e com os sensores combinados (vis-NIR+XRF). Os desempenhos foram apresentados para os modelos PLS usando as bibliotecas locais e para o modelo cubista usando os dados da biblioteca nacional. A redução ou aumento do RMSE (RI%) em relação ao desempenho individual do sensor vis-NIR e em relação ao do sensor XRF também foram apresentados.**

Local libraries	PLS Models (Local libraries)					Cubist Models (National library)				
	vis-NIR	XRF	vis-NIR+XRF	RI% vs vis-NIR	RI% vs XRF	vis-NIR	XRF	vis-NIR+XRF	RI% vs vis-NIR	RI% vs XRF
1	1.05	1.38	**0.96**	-9%	-30%	**1.17**	3.11	2.70	131%	-13%
2	**1.72**	1.8	1.84	7%	2%	1.80	2.25	**1.60**	-11%	-29%
3	2.75	2.79	**2.19**	-20%	-22%	6.31	5.07	**3.37**	-47%	-34%
4	0.77	0.85	**0.73**	-5%	-14%	0.99	1.13	**0.95**	-4%	-16%
5	2.02	1.84	**1.59**	-21%	-14%	3.46	5.66	**2.75**	-21%	-51%
6	2.22	1.97	**1.64**	-26%	-17%	2.81	2.14	**1.63**	-42%	-24%
7	0.87	1.46	**0.82**	-6%	-44%	2.60	**1.39**	1.47	-43%	6%
8	1.99	1.68	**1.49**	-25%	-11%	1.71	3.04	**1.54**	-10%	-49%
9	2.80	2.61	**2.58**	-8%	-1%	3.45	3.56	**2.82**	-18%	-21%
Mean	1.80	1.82	**1.54**	-15%	-16%	2.70	3.04	2.09	-23%	-31%

Figure 3 shows the predictive error of the cubist model (using the national spectral library) for each sample as a function of its SOC content. It can be seen that the models performed worse for samples with SOC contents greater than 18 g kg^{-1}, which must be related to the low number of samples in the national library with contents above this value (see Figure 2). Thus, enriching the model with samples with SOC content greater than 18 g kg^{-1} should improve the performance of the scenarios presented in this study. Finally, Figure 4 shows the scatter plots of the SOC predictions using vis-NIR+XRF and cubist modeling. In summary, the findings of this study demonstrate that the integration of data from both vis-NIR and XRF sensors offers synergistic advantages for predicting SOC. However, the accuracy of individual models utilizing vis-NIR sensors may be adequate for the intended application, and users should weigh the cost-benefit of incorporating XRF accordingly. The results presented here can be used as reference for laboratories to make informed decisions when selecting sensors or sensor combinations for SOC prediction, as well as to comprehend the potential accuracy of SOC determination via sensors in Brazilian tropical soils.

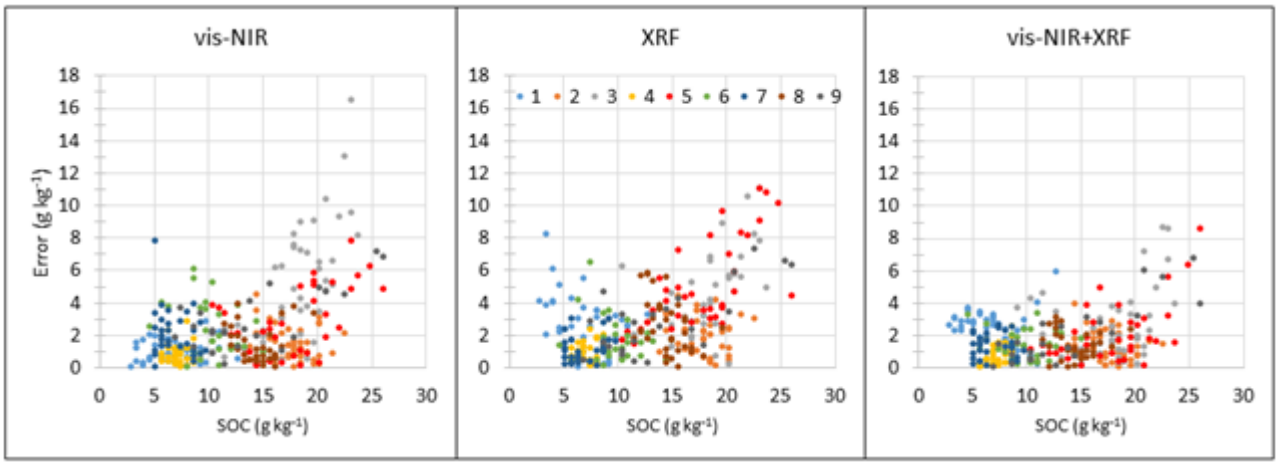


FIGURE 3. Scatter plots showing the error and SOC content of each sample for the predictions using vis-NIR, XRF and vis-NIR+XRF sensors. Samples from local libraries 1-7 are shown in different colors. **Gráficos de dispersão mostrando o erro e o teor de SOC de cada amostra para as predições usando sensores vis-NIR, XRF e vis-NIR+XRF. Amostras das bibliotecas locais 1?7 foram apresentadas em diferentes cores.**

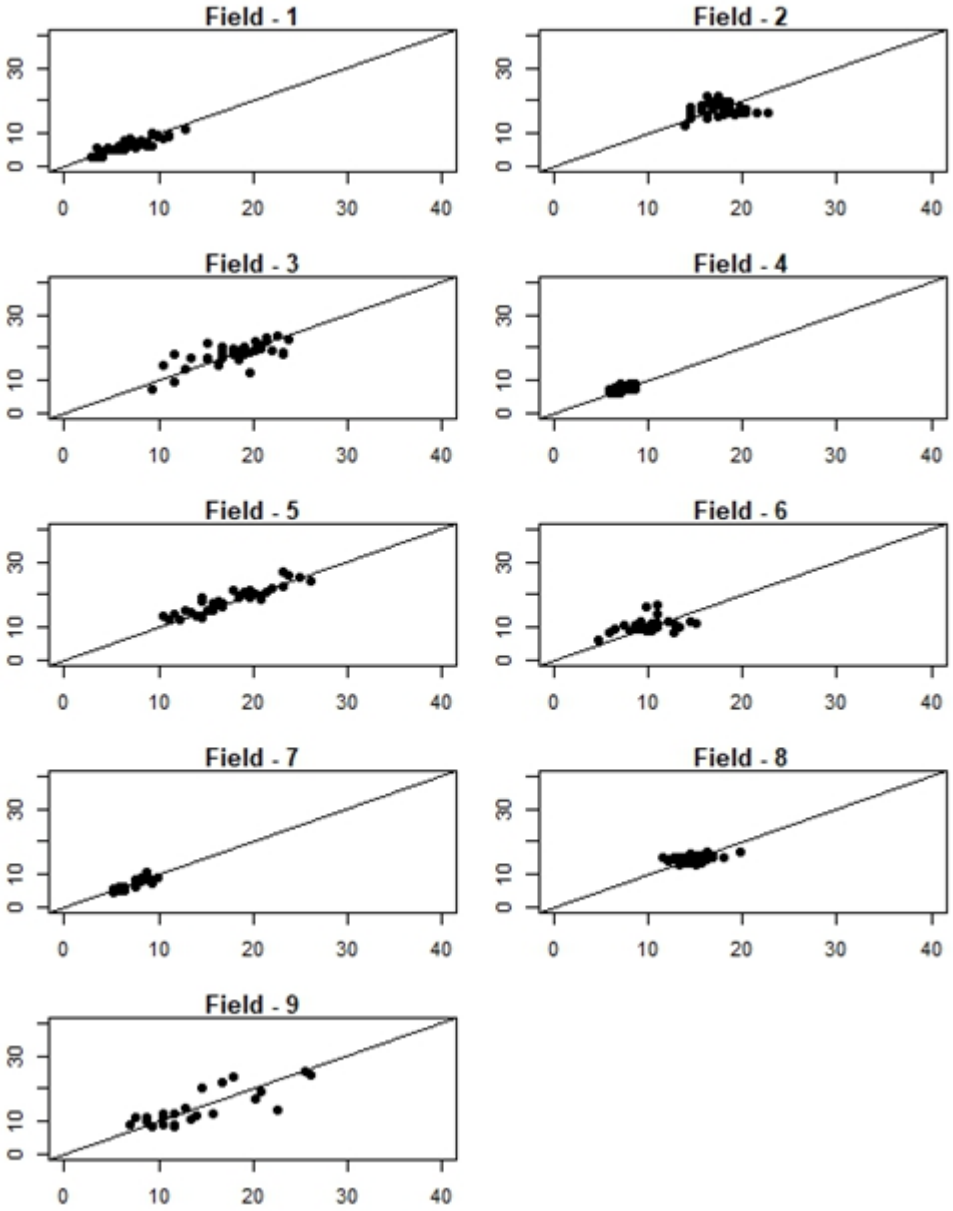


FIGURE 4. Descriptive statistics of soil chemical attributes for the calibration and validation set. **Gráficos de dispersão de SOC previsto versus medido usando dados VNIR+XRF e modelos cubistas. Os valores medidos são exibidos no eixo X e os previstos no eixo Y.**

CONCLUSÃO

This study is a pioneer in evaluating the performance of spectral libraries using vis-NIR and XRF sensors in Brazilian tropical soils. Cubist models were used for predictive modeling of SOC derived from spectral data of vis-NIR and XRF sensors used individually and combined by spectral concatenation. Nine areas, in different geographical positions (from the State of Paraná to Maranhão), with local spectral libraries were used to evaluate the models. The results showed that local modeling had in general a lower RMSE than cubist models in all scenarios of sensors. Local models using

combined spectra (vis-NIR+XRF) had an error reduction of 15% in relation to models using only vis-NIR data and a 16% reduction in relation to models using only XRF. The performance gain achieved for the data fusion (vis-NIR+XRF) was greater for the cubist models applied to the national spectral library, for which models using a combination of spectra showed a reduction of 23% in relation to vis-NIR and 31% in relation to XRF. The RMSE achieved for the prediction of SOC using the national spectral library was 2.70 g kg^{-1} for the vis-NIR alone, 3.04 g kg^{-1} for the XRF, and 2.09 g kg^{-1} for the fusion of both sensors. The fusion of vis-NIR and XRF sensors data enhances SOC prediction using national spectral libraries in Brazilian tropical soils.

AGRADECIMENTOS

We would like to thank the company Ribersolo Laboratório de Análises Agrícolas for their support with the reference analyses, as well as FAPESP for the financial support given to the first author (process no. 2020/16670-9).

REFERÊNCIAS

Ben-Dor, E., 2002. Quantitative remote sensing of soil properties. Adv. Agron. 75, 173-243. https://doi.org/10.1016/S0065-2113(02)75005-0

Cezar, E., Nanni, M.R., Guerrero, C., da Silva Junior, C.A., Cruciol, L.G.T., Chicati, M.L., Silva, G.F.C., 2019. Organic matter and sand estimates by spectroradiometry: Strategies for the development of models with applicability at a local scale. Geoderma 340, 224-233. https://doi.org/https://doi.org/10.1016/j.geoderma.2019.01.021

Guerrero, C., Stenberg, B., Wetterlind, J., Viscarra Rossel, R.A., Maestre, F.T., Mouazen, A.M., Zornoza, R., Ruiz-Sinoga, J.D., Kuang, B., 2014. Assessment of soil organic carbon at local scale with spiked NIR calibrations: effects of selection and extra-weighting on the spiking subset. Eur. J. Soil Sci. 65, 248-263. https://doi.org/10.1111/ejss.12129

Minasny, B., McBratney, A.B., 2008. Regression rules as a tool for predicting soil properties from infrared reflectance spectroscopy. Chemom. Intell. Lab. Syst. 94, 72-79. https://doi.org/10.1016/j.chemolab.2008.06.003

Morona, F., dos Santos, F.R., Brinatti, A.M., Melquiades, F.L., 2017. Quick analysis of organic matter in soil by energy-dispersive X-ray fluorescence and multivariate analysis. Appl. Radiat. Isot. 130, 13-20. https://doi.org/https://doi.org/10.1016/j.apradiso.2017.09.008

Ng, W., Minasny, B., Jones, E., McBratney, A., 2022. To spike or to localize? Strategies to improve the prediction of local soil properties using regional spectral library. Geoderma 406, 115501. https://doi.org/10.1016/j.geoderma.2021.115501

Padarian, J., Minasny, B., McBratney, A.B., 2019. Transfer learning to localise a continental soil vis-NIR calibration model. Geoderma 340, 279-288. https://doi.org/10.1016/j.geoderma.2019.01.009

Shi, X., Song, J., Wang, H., Lv, X., Zhu, Y., Zhang, W., Bu, W., Zeng, L., 2023. Improving soil organic matter estimation accuracy by combining optimal spectral preprocessing and feature selection methods based on pXRF and vis-NIR data fusion. Geoderma 430, 116301. https://doi.org/https://doi.org/10.1016/j.geoderma.2022.116301

Tavares, T.R., Molin, J.P., Nunes, L.C., Alves, E.E.N., Melquiades, F.L., de Carvalho, H.W.P., Mouazen, A.M., Carvalho, H.W.P. de, Mouazen, A.M., 2020a. Effect of X-Ray Tube Configuration

on Measurement of Key Soil Fertility Attributes with XRF. Remote Sens. 12, 963. https://doi.org/10.3390/rs12060963

Tavares, T.R., Mouazen, A.M., Alves, E.E.N., Dos Santos, F.R., Melquiades, F.L., De Carvalho, H.W.P., Molin, J.P., 2020b. Assessing soil key fertility attributes using a portable X-ray fluorescence: A simple method to overcome matrix effect. Agronomy 10. https://doi.org/10.3390/agronomy10060787

Walkley, A., Black, I.A., 1934. An examination of the degtjareff method for determining soil organic matter, and a proposed modification of the chromic acid titration method. Soil Sci. 37.

Y?lmaz, D., Boyda?, E., 2018. The use of scattering peaks for matrix effect correction in WDXRF analysis. Radiat. Phys. Chem. 153, 17-20. https://doi.org/10.1016/j.radphyschem.2018.08.035

AVALIAÇÃO DE UM IMPLEMENTO PARA MENSURAÇÃO DE CONDUTIVIDADE ELETRICA APARENTE DO SOLO UTILIZANDO INSTRUMENTAÇÃO COM BASE EM CORRENTE CONTÍNUA

SAMARA CRISTINA ROSA [1]; EDIVAN HENRIQUE DE ANDRADE PERES [2]; RODRIGO SINAIDI ZANDONADI [3]

[1]Discente. Av. Alexandre Ferronato, 1200 - Res. Cidade Jardim, Sinop - MT. Universidade Federal de Mato Grosso - Campus Sinop; [2]Discente. Av. Alexandre Ferronato, 1200 - Res. Cidade Jardim, Sinop - MT. Universidade Federal de Mato Grosso - Campus Sinop; [3]Docente. Av. Alexandre Ferronato, 1200 - Res. Cidade Jardim, Sinop - MT. Universidade Federal de Mato Grosso - Campus Sinop

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A condutividade elétrica aparente (CEa) do solo é uma importante ferramenta na agricultura de precisão e tem sido utilizada para auxiliar nos estudos de atributos físicos e químicos de solo. Com intuito de fazer trabalhos com CEa na região norte de mato grosso, pesquisadores desenvolveram a instrumentação com base em corrente contínua e um implemento com a mecânica diferente dos equipamentos comerciais disponibilizados no Brasil. O objetivo deste trabalho foi avaliar o aparato desenvolvido (implemento mais eletrônica embarcada) considerando a relação das leituras de CEa com teor de argila do solo. O estudo foi realizado no município de Tabaporã, norte do estado de Mato Grosso, em duas áreas com diferentes faixas de teor de argila. Coletas de amostra solo foram conduzidas pelo método grade em célula sendo que os limites foram também utilizados para agrupar os dados de CEa e fazer cálculo da média permitindo a análise de Correlação e Pearson e análise de regressão. Os resultados apontam a qualidade satisfatória dos dados registrados pelo sistema em estudo além de coeficientes de correlação altos e significativos para ambas as áreas estudas, sendo 0,81 e 0,95 para os talhões T01 e T02 respectivamente. Os resultados encontrados nesse estudo demonstram que foi possível utilizar o aparato desenvolvido para medir satisfatoriamente os padrões comportamentais de CEa do solo nos talhões avaliados.

PALAVRAS-CHAVE: Textura de Solo; Produção de Grãos; Instrumentação

ABSTRACT

Apparent Soil Electrical Conductivity (ECa) is an important toll in Precision Agriculture and has been extensively used to assist studies of soil physical and chemical attributes. In order to allow research activities in northern region of Mato Grosso, researchers developed an instrumentation setup based on direct current and also an implement with different mechanisms found in the commercial equipment available in Brazil. The objective of this work was to evaluate the performance of the system considering the quality of ECa data registered by the data acquisition and its correlation with soil clay content. The study was conducted in an area located in Tabaporã, northern region of Mato Grosso. Two fields with different soil texture characteristics used for data collection. Soil sample was collected in the area using the grid-in-cell method. The limits of the grid were used for grouping de ECa data to calculate its average for correlation analysis using Pearson Correlation method. The results indicated that the proposed setup was capable of register good quality ECa data and the correlation coefficient were high and significant for both studies fields resulting in 0.81 and 0.95 for fields T01 and T02 respectively. Based on the results, it was concluded that the proposed setup can satisfactorily measure the behavioral patterns of soil ECa in the evaluated fields.

KEYWORDS: ;

INTRODUÇÃO

A condutividade elétrica aparente do solo (CEa), é uma importante ferramenta no âmbito da agricultura de precisão, que tem sido utilizada para estudar a variabilidade espacial de propriedades do solo como: salinidade, quantidade e estratificação de camadas de argila, umidade do solo e matéria orgânica (CORWIN & LESCH 2005).

Vários trabalhos com CEa do solo têm sido conduzidos no brasil (Machado *et al*., 2006; Molin *et al*., 2005; Molin and Rabello, 2011; Santana et al., 2006; Borba *et al.*, 2016), muito pouco se encontra sobre trabalhos conduzidos na região norte de Mato Grosso.

Com o intuito de estudar CEa do solo no norte de Mato Grosso, Barbosa; Zandonadi (2017) e Schwengber, *et al.* (2018), desenvolveram, com base no modelo de "quatro pontas" (Smits,1958; Corwin; Hedrickx, 2002; Corwin; Lesh, 2003), a eletrônica para determinação da CEa do solo com base em corrente contínua, assim como, um implemento que permitisse a mensuração continua desse atributo nas áreas de produção de grãos do norte de Mato Grosso. Schwengber, *et al.* (2018) apresentou um mapa de CEa confeccionado a partir de dados do aparato desenvolvido, mas não apresentou um estudo associando a CEa mensurada com atributos do solo. Como o sistema proposto difere tanto no princípio da instrumentação quanto na mecânica do implemento, estudos relacionando a CEa obtida com os atributos de solo se fazem necessários.

OBJETIVOS

Diante do exposto, o objetivo desse trabalho foi avaliar o desempenho do aparato desenvolvido (implemento mais eletrônica embarcada) considerando a relação das leituras de CEa registradas com o teor de argila do solo. levando em consideração a qualidade dos dados de CEa registrados e a sua correlação com o teor de argila do solo, semelhantemente aos sistemas comerciais utilizados na maior parte dos trabalhos de pesquisas encontrados na literatura.

MATERIAL E MÉTODOS

O estudo foi conduzido na Fazenda Gobbi, região norte do Estado de Mato Grosso (IBGE, 2023), no município de Tabaporã fazendo-se a coleta de dados em dois talhões (T01 e T02 com 91,3 e 107,6 ha respectivamente) com evidentes diferenças nas classes do teor de argila.

Para caracterizar o teor de argila dos talhões abordados no estudo, realizou-se em janeiro de 2017, a coleta de amostras de solo utilizando a metodologia de grade em células (2 ha). Cada célula foi representada por 15 a 20 subamostras aleatórias sendo o solo coletado na profundidade de 0 a 20 cm utilizando um amostrador SoloDrill da Falker (https://falker.com.br/br/solodrill) acoplado a um quadriciclo. Após a coleta, as amostras foram secas em uma estufa por 48 horas a uma temperatura de 60°C, embaladas em pacotes plásticos e identificadas com o nome da célula de onde foi coletada. Para viabilizar a coleta pelo método mencionado (grade em célula), foi utilizado um programa computacional com interface gráfica desenvolvido na plataforma Matlab (2017) permitindo assim a navegação e identificação das células a serem representadas.

Para a coleta de dados de CEa do solo, a fazenda Gobbi disponibilizou um trator John Deere com sistema de direcionamento automático corrigido por sinal RTK (correção em tempo real cinemática) e disponibilidade de VCR (válvula de comando remoto hidráulico). Os dados de CEa foram armazenados no sistema de aquisição de dados por meio do cartão SD (Secure Digital) no formato de arquivo de texto. O aparato desenvolvido e testado (Barbosa; Zandonadi (2017) e Schwengber, *et al.* (2018), também contava com um programa computacional com interface gráfica (desenvolvido na plataforma Matlab 2017 e instalado em um tablet Surface Pro da Microsoft) para visualização dos

dados em tempo real durante a coleta, permitindo monitorar a velocidade de trabalho, o comportamento da CEa e o mapa de cobertura gerada na coleta de dados.

Como a coleta da CEa deve ser realizada com certo teor de umidade no solo, a janela de trabalho e disponibilidade de máquina precisam ser ajustadas para se adequar à rotina da fazenda e não atrapalhar as operações em andamento. Diante deste cenário, foi possível realizar a coleta de CEa previamente à semeadura da soja em novembro de 2018 no T01 e outubro de 2017 no T02. Ambos foram trabalhados com velocidade de 10 a 15 km h^{-1}, com uma faixa de trabalho definida de 30 metros.

Para processamento e análise dos dados coletados de CEa e resultados das análises de amostras de solo, foram utilizados os programas MatLab 2023 e Excel 2023 (Microsoft) permitindo os tratamentos necessários, assim como a geração de gráficos e mapas apresentados neste trabalho. Gráficos de caixa foram utilizados para representar a estatística descritiva e visualizar valores discrepantes (*outliers*) representando 99.3 % da cobertura da distribuição de dados (se considerado com distribuição normal) (MathWorks 2023a).

Uma vez realizada a filtragem dos dados de CEa, foi conduzido o cálculo da média dos valores de CEa contidos nos limites de cada célula proporcionando a análise de correlação entre valores de argila (obtidos nas análises de solo) e os valores médios de CEa. Os mapas de CEa e argila foram confeccionados, assim como, os gráficos de dispersão entre CEa e teor de argila para os talhões estudados.

Para avaliar a correlação entre as variáveis, foi utilizado a função corrcoef (Mathworks 2023b) que calcula o Coeficiente de Correlação de Pearson (r) assim como o p-valor (valor de probabilidade) associado ao teste de hipótese nula utilizando o teste t. Foi realizado também a regressão linear para ajuste de equação e cálculo dos valores do coeficiente de determinação R^2 e erro médio quadrado (mse).

RESULTADOS E DISCUSSÃO

O resultado da análise descritiva de CEa foram apresentados na Figura 1 (a e b) através dos gráficos de caixa gerados para os dados brutos e filtrados respectivamente. É possível observar que a variação em torno da média para os dois talhões foi semelhante levando em consideração a distância interquartil, enquanto o valor de CEa média foi maior para o T01. Esse comportamento pode ser explicado pelo fato da coleta de CEa ter acontecido em diferentes épocas (novembro e outubro respectivamente), favorecendo maior acúmulo de chuvas no T01.

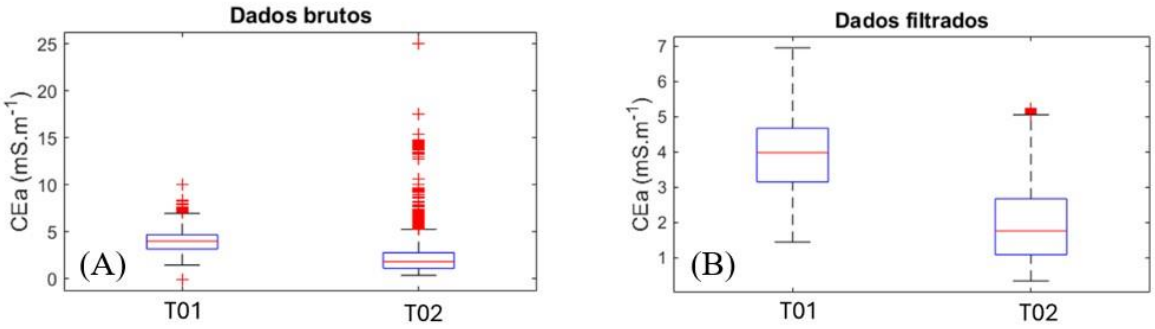


Figura 1: Gráfico de caixa representando a estatística descritiva dos dados (brutos (A) e filtrados (B)) coletados de CEa de solo nos talhões 1 e 2.

Em relação ao procedimento de filtragem, nota-se nos gráficos de caixa (Figura 1) que o critério para eliminação de "*outliers*" foi satisfatório, especialmente após analisar

a consistência dos dados de CEa apresentados nos mapas da Figura 2. Vale ressaltar a evidente variação nos valores e a suave transição entre os diferentes padrões de CEa apresentados nos mapas, indicando que método com base em corrente contínua acoplado ao implemento proposto, foi capaz de mensurar e armazenar os dados de CEa satisfatoriamente.

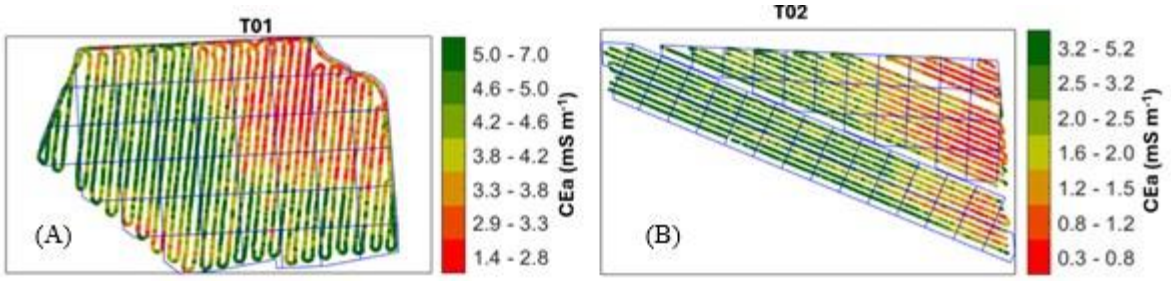


Figura 2: Mapas representando o comportamento da CEa dos dois talhões em estudo, confeccionados a partir de dados filtrados coletados pelo aparato em teste e visualização da grade em células utilizada para fazer a coleta de amostra de solo e calcular o valor médio de CEa.

Mapas com valore das médias por célula CEa e teor de argila, foram confeccionados (Figura 3), onde pode se observar a nítida semelhança de comportamento entre os padrões de CEa e argila para ambos os talhões avaliados.

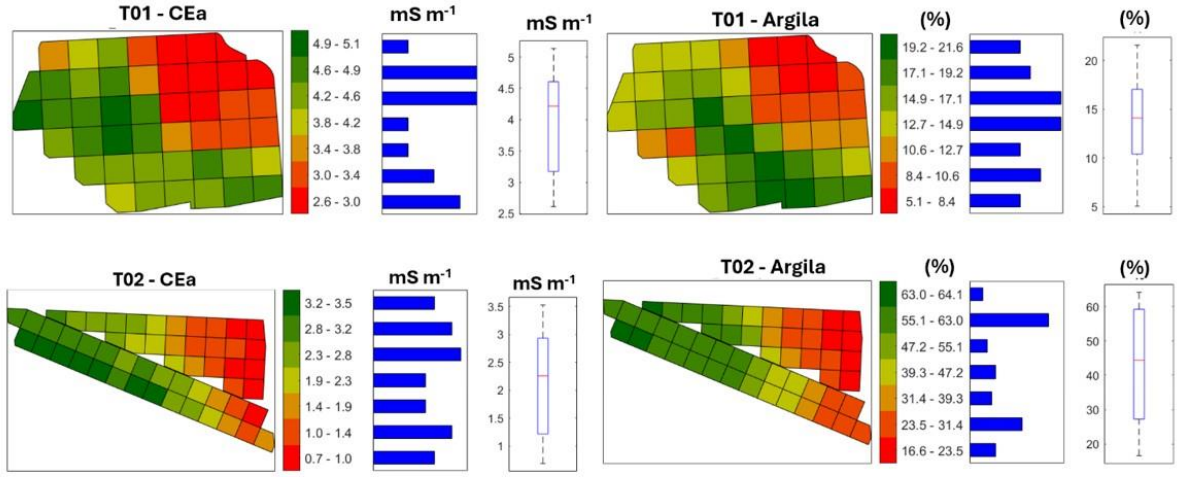


Figura 3: Mapas produzidos com as médias de CEa e teor de Argila para os talhões estudados acompanhados de gráfico de barras representando a distribuição das diferentes classes de leitura de CEa e o gráfico de caixa representando a estatística descritiva dos valores de CEa. Mapas de CEa dos talhões T01 e T02 em (A) e (C) e mapas de teor de argila em (B) e (D).

Os resultados da análise de Correlação de Pearson (r), assim como alguns parâmetros de estatística descritiva são apresentados na Tabela 1, e os gráficos de dispersão apresentados na Figura 4. Nota-se que o coeficiente de correlação foi alto e significativo para os talhões estudados corroborando com estudos encontrados na literatura em que avaliação foi conduzida com sistema comercial de mensuração de CEa utilizando corrente alternada, como por exemplo (SUDDUTH *et al*., 2005) em algumas áreas nos EUA e Borba *et al*., (2016) no sul do estado de Mato Grosso.

Vale ressaltar que, o coeficiente de correlação entre CEa e teor de argila é maior na medida em que a variação do teor de argila aumenta. Em casos em que a área estudada apresenta pouca variação no

teor de argila, outros atributos de solo podem influenciar o comportamento da condutividade elétrica fazendo com que a correlação entre a argila e CEa perca a significância. No caso das áreas estudadas, a variação de argila no T02 é consideravelmente maior que no T01 e isso é refletido no coeficiente de correlação com CEa mensurada. Uma análise semelhante pode ser feita em relação ao coeficiente de determinação (R^2) das equações ajustadas uma vez que o R^2 da equação ajustada para os dados do T02 foi maior que o T01.

Tabela 1: Resultados da análise de correlação entre CEa e teor de argila e alguns parâmetros descritivos das variáveis estudadas.

	Média CEa	Faixa CEa	Média % argila	Faixa % argila	(r) Coeficiente de Pearson (CEa X %argila)	p-valor	R^2	mse
T01	3.98	2.58	13.81	16.49	0.81	0.000	0.62	0.24
T02	2.11	2.84	43.26	47.52	0.95	0.000	0.88	0.08

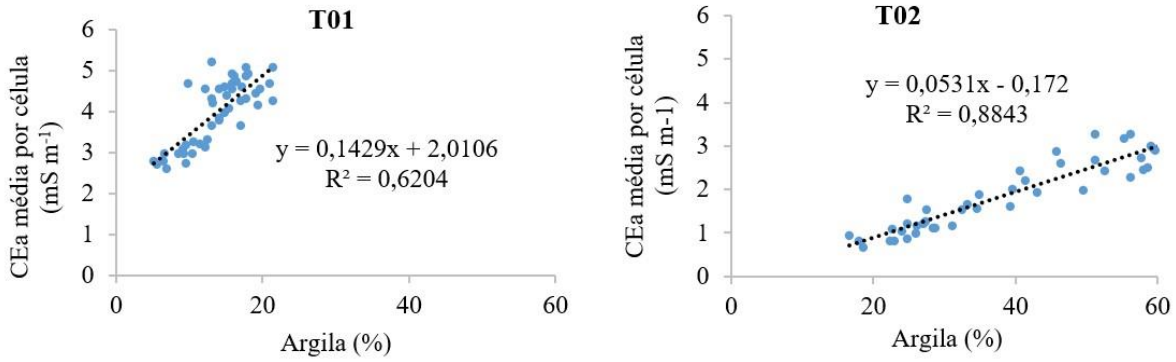


Figura 4: Gráficos de dispersão gerados a partir dos dados de CEa e % de argila para talhões estudados.

CONCLUSÃO

De acordo com os resultados nesse estudo, pode-se concluir que o aparato para leitura de CEa com base em corrente contínua, acoplado ao implemento desenvolvido para aquisição de dados contínuos em áreas de produção de grãos e fibras, foi capaz de mensurar satisfatoriamente, padrões de comportamento de CEa do solo relacionados ao teor de argila presentes nas áreas.

Nas áreas avaliadas a CEa foi capaz de representar a variação do teor argila apresentado significativos coeficientes de correlação.

AGRADECIMENTOS

MVR agro por viabilizar recursos financeiros para a construção do equipamento. Fazenda Gobbi por disponibilizar infraestrutura e recursos financeiros para execução do trabalho apresentado.

REFERÊNCIAS

ALBORNOZ, V. M.; Nestor M. CID-GARCÍA, N. M.; ORTEGA, R. A. et al. Determinación de Zonas Homogéneas de Cultivo Usando Agricultura De Precisión. In: Congreso Latino-Iberoamericano de Investigación Operativa, 2012, Rio de Janeiro. Anais... Rio de Janeiro: Simpósio Brasileiro de Pesquisa Operacional, 2012. p. 4540- 4547.

ARAÚJO, E. G., CORRÊA, A. R., LIMA, D. C. de O. S., PRANDO, E. de P., SENA, K. N., MONTANARI, R., SILVA, R. M.; Análise espacial da condutividade elétrica e atributos físico-químicos de um Latossolo. Revista Agrarian, Dourados, v.9, n.31, p.73-83, 2016.

BARBOSA, F. S.; ZANDONADI, R. S.; Low cost apparatus for apparent soil electrical conductivity measurement based on direct current. Revista Nativa, Sinop, v.5,n1, p.37-41, 2017.

BORBA, M. Z. de.; FREDDI, O. da S.; TREVISAN, R. G.; Molin, J. P. Condutividade elétrica aparente no mapeamento da textura do solo. In: XXXV Congresso Brasileiro de Ciência do Solo, Natal, 2015.

CORWIN, D. L.; HENDRICKX, J. M. H. Electrical resistivity: WennerArray. In: SILVA, J. S. Methods of soil analysis part 4 physicalmethods. Madison, Wisconsin, USA. SSSA Boock Series, n.5,p. 1282-1287, 2002.

CORWIN, D. L.; LESCH, S. M. Application of soil electrical conductivity to precision agriculture: theory, principles, and guidelines. Agronomy Journal, Madison, v. 95, n. 3, p. 471-471,2003.

CORWIN, D.L., LESCH, S.M., Apparent soil electrical conductivity measurements in agriculture. Computers and Electronics in Agriculture, 46, 11-43, 2005.

IBGE. Portal Cidades. Rio de Janeiro, 2023. Disponível em: https://cidades.ibge.gov.br/brasil/mt/tabapora/panorama. Acesso em: 07 abr. 2024.

MACHADO, P. L. O. de A.; BERNARDI, A. C. de C.; VALENCIA, L. I. O.; MOLIN, J. P.; GIMENEZ, L. M.; SILVA, C. A.; ANDRADE, A. G. de; MADARI, B. E.; MEIRELLES, M. S. P. Mapeamento da condutividade elétrica e relação com a argila de Latossolo sob plantio direto. Revista Pesquisa Agropecuária Brasileira, Brasília, v. 41, n. 6, p. 1023-1031, jun. 2006.

MOLIN, J. P.; GIMENEZ, L. M.; PAULETTI, V.; SCHMIDHALTER, U.; HAMMER, J. Mensuração da condutividade elétrica do solo por indução e sua correlação com fatores de produção. Revista Engenharia Agrícola, Jaboticabal, v.25, n.2, p.420-426, maio/ago. 2005.

RABELLO, L. M.; BERNARDI, A. C. de C.; INAMASU, R. Y. Condutividade elétrica aparente do solo. In: BERNARDI, A. C. de C.; NAIME, J. de M.; RESENDE, A. V. de; BASSOI, L. H.; INAMASU, R. Y. (Ed.). Agricultura de precisão: resultados de um novo olhar. Brasília, DF: Embrapa, 2014. p. 48-57; 2014.

ROMERO, C. W. S., LIMA, E.S., LOVERA, L. H., SILVA, T. S., Fábio, F. H. Variabilidade Espacial da Condutividade Elétrica do Solo Correlacionados com a Matéria Orgânica e Argila. Anais [...]. IV Simpósio de Geoestatística Aplicada em Ciências Agrárias, p.1-5, 2015. FCA/UNESP.

SMITS, F. M. Measurements of sheet resistivities with the fourpointprobe. The Bell System Technical Journal, New York, v. 37, p. 711-718, 1958.

SUDDUTH, K. A.; KITCHEN, N. R.; WIEBOLD, W. J. Relating apparent electrical conductivity to soil properties across the north-central USA. Revista Computers and Electronics in Agriculture, 46: 263- 283, 2005.

The MathWorks Inc. In: MathWorks documentation: boxplot. Disponíveis: <https://www.mathworks.com/help/stats/boxplot.html?searchHighlight=boxplot&s_tid=srchtitle_support_results_1_boxplot>. Acesso em: 06 mar. 2024.

The MathWorks Inc. In: MathWorks documentation: corrcoef. Disponíveis:<https://www.mathworks.com/help/matlab/ref/corrcoef.html>. Acesso em: 06 mar. 2024.

TRANSPARÊNCIA E SELEÇÃO DE BANDAS ESPECTRAIS PARA A MODELAGEM DE CARBONO ORGÂNICO E NITROGÊNIO DO SOLO POR SENSORIAMENTO PRÓXIMO

Erli Pinto dos Santos [1]; Renata Ranielly Pedroza Cruz [2]; Gloria Milena Rojas Plazas [3]; Uemeson José dos Santos [4]; Michel Castro Moreira [5]

[1]D.Sc. em Engenharia Agrícola, Pós-doutorando. Viçosa - MG. Departamento de Engenharia Agrícola, Universidade Federal de Viçosa; [2]D.Sc. em Fitotecnia, Pós-doutoranda. Viçosa - MG. Departamento de Agronomia, Universidade Federal de Viçosa; [3]Doutoranda em Engenharia Agrícola. Viçosa - MG. Departamento de Engenharia Agrícola, Universidade Federal de Viçosa; [4]D.Sc. em Tecnologias Energéticas e Nucleares, Professor. Santarém - PA. Instituto Federal de Educação, Ciência e Tecnologia do Pará; [5]D.Sc. em Engenharia Agrícola, Professor. Viçosa - MG. Departamento de Engenharia Agrícola, Universidade Federal de Viçosa

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

O carbono orgânico do solo (COS) e o nitrogênio (N) são essenciais para a saúde do solo, a produção agrícola e o funcionamento dos ecossistemas. No entanto, as medições convencionais desses atributos são trabalhosas e caras. A espectroscopia de reflectância surge como uma alternativa promissora, mas ainda está em fase de aprimoramento. Este estudo tem como objetivo avaliar a acurácia da predição de teores de COS e N total usando a reflectância do solo e os métodos de machine learning PLS (Partial Least Squares) e LASSO (Least Absolute Shrinkage and Selection Operator). Os resultados indicam que os modelos PLS têm maior precisão para predizer N total, enquanto o LASSO foi mais eficiente para predizer o teor de COS. Contudo, o LASSO demonstrou a vantagem adicional de gerar modelos mais transparentes, permitindo uma análise direta das bandas espectrais do visível ao infravermelho próximo utilizadas na modelagem.

PALAVRAS-CHAVE: reflectância do solo; machine learning; saúde do solo

ABSTRACT

Soil organic carbon (SOC) and nitrogen (N) are essential for soil health, crop yield, and ecosystem functioning. However, traditional soil analyses for these attributes are laborious and expensive. Reflectance spectroscopy, though still evolving, emerges as a promising alternative. This study aims to assess the prediction accuracy of SOC and total N contents using Partial Least Squares (PLS) and Least Absolute Shrinkage and Selection Operator (LASSO) machine learning methods. The results indicate that PLS models were more accurate in predicting total N, while LASSO was more effective in predicting SOC contents. Furthermore, LASSO demonstrated the additional advantage of generating transparent models, as it allowed for the direct analysis of causal relationships between the selected visible to near-infrared spectral bands and the modeled attributes.

KEYWORDS: soil reflectance; machine learning; soil health

INTRODUÇÃO

O carbono orgânico do solo (COS) e o nitrogênio (N) são importantes atributos do solo para a produção agrícola. O COS é a principal fração da matéria orgânica do solo (MO), que atua na regulação do clima, no armazenamento de água e fertilidade do solo (WIESMEIER et al., 2019). Já o N é um dos macronutrientes que mais limitam a produção agrícola, e no solo está predominantemente como parte da MO (CANTARELLA, 2007).

A demanda por análise de solo tem aumentado em todo o mundo, frente à adoção de práticas de agricultura de precisão e manejo conservacionista do solo (ANGELOPOULOU et al., 2020), aumentando também o consumo de reagentes para análise de solo. Por isso a espectroscopia de solo é um método alternativo, rápido e não-destrutivo, de análise de solo (DEMATTÊ et al., 2019). A espectroscopia de solos é um método de sensoriamento próximo que consiste em medir a reflectância de amostras, comumente nos espectros do visível, infravermelho próximo e de ondas curtas (Vis-NIR-SWIR). Com a reflectância medida e usando modelos *Machine Learning* (ML), como o PLS (*Partial Least Squares*), atributos do solo são estimados. No entanto, a modelagem de atributos do solo com métodos de ML requer transparência dos modelos (MCBRIDE, 2022). Por isso estudos recentes têm proposto o uso de métodos diagnósticos para interpretação de modelos e métodos de regressão transparentes, como o LASSO (*Least Absolute Shrinkage and Selection Operator*) (DOS SANTOS et al., 2023).

OBJETIVOS

Assim, o objetivo deste trabalho foi testar a acurácia dos modelos PLS e LASSO na predição de COS e N total, explorando como o método LASSO pode melhorar a transparência na modelagem por meio de sensoriamento proximal nos espectros Vis-NIR-SWIR.

MATERIAL E MÉTODOS

Os dados de solo foram obtidos a partir de levantamentos de perfis em campo, em áreas de agricultura, pastagem e de vegetação nativa ao longo do Estado de Pernambuco. As amostras da SSL foram coletadas de 127 perfis de solo em sete diferentes classes de solo: Argissolos (35 perfis e 210 amostras), Latossolos (11 p. e 77 a.), Neossolos Litólicos (23 p. e 84 a.), Planossolos (23 p. e 117 a.), Neossolos Quartzarênicos (11 p. e 74 a.), Luvissolos (12 p. e 68 a.) e Neossolos Regolíticos (12 p. e 71 a.). Essas amostras foram coletadas de trincheiras em sete camadas padronizadas em profundidade: 0 - 10, 10 - 20, 20 - 30, 30 - 40, 40 - 60, 60 - 80 e 80 - 100 cm. As amostras foram então processadas em laboratório para a determinação analítica de teores de COS e N total. Os teores foram determinados via combustão seca usando o analisador TruSpec CHN com amostra sólida modulada e operada a 900 °C (LECO ® 2006, St. Joseph, MI, USA).

Após determinação analítica, foram obtidas as curvas de reflectância no espectro Vis-NIR-SWIR para montar a biblioteca espectral (SSL), tendo sido usado o espectrorradiômetro FieldSpec 3 (Analytical Spectral Devices Inc., Boulder, CO, USA). Assim, curvas com 2151 bandas espectrais foram obtidas entre 350 e 2500 nm. As curvas de reflectância originais foram suavizadas com filtro Savitzky-Golay, em seguida foram calculadas curvas de reflectância normalizada e de absorbância. A reflectância normalizada foi usada para predizer teores de COS, enquanto a absorbância para teores de N total (SANTOS et al., 2020).

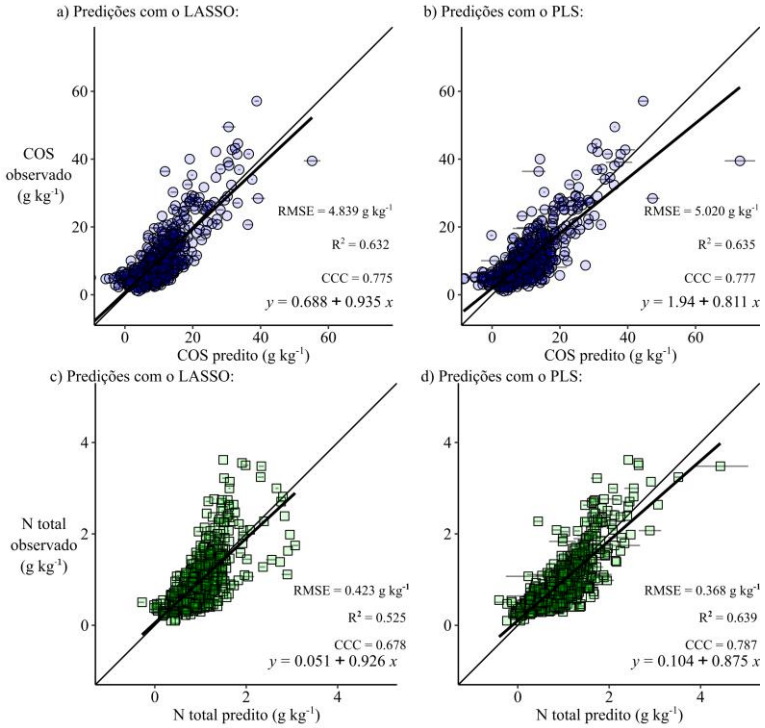
A etapa seguinte foi de criação dos modelos, em que a SSL foi dividida aleatoriamente em dois subconjuntos de dados: um para treinamento e outro para teste (validação externa) dos modelos. 102 perfis (80%) foram usados para treinar os modelos, e 25 (20%) para testá-los. Essa divisão foi feita de forma aleatória por 10 vezes, recursivamente, para gerar 10 repetições de modelagem para cada atributo de interesse. Em cada repetição os modelos foram otimizados por meio do ajuste dos hiperparâmetros através de validação cruzada Leave-Soil-Profile-Out (DOS SANTOS et al., 2023). Todo o processamento foi realizado em **linguagem R**, com software **RStudio**.

Os modelos foram avaliados com dados de teste usando as métricas: raiz do erro quadrático médio (RMSE), coeficiente de determinação (R^2) e coeficiente de correlação e concordância de Lin (CCC). Além disso, o teste Mann-Whitney foi usado para comparar os valores de CCC obtidos entre os modelos PLS e LASSO para cada atributo (SAFANELLI et al., 2023). A hipótese nula é de que as

amostras de CCC são similares ao nível de significância de 0.05. Por fim, a importância das bandas espectrais para os modelos foi medida usando a métodos do pacote **vip** (GREENWELL; BOEHMKE, 2020).

RESULTADOS E DISCUSSÃO

As predições de teores de COS e N total são exibidas na FIGURA 1, onde são destacados a média das métricas de ajuste dos modelos. O gráfico da FIGURA 1a) exibe os valores preditos e observados de COS (g kg^{-1}) por modelos LASSO. Já o gráfico da FIGURA 1b) exibe os valores de COS preditos por modelos PLS. Avaliando as métricas obtidas nos dois tratamentos, observa-se que o RMSE foi menor para os modelos LASSO. Além disso, os valores observados são compatíveis com a literatura, onde valores de RMSE na faixa de 0.3 a 25 g kg^{-1} (SANTOS et al., 2020). O gráfico da FIGURA 1c) exibe os valores preditos e observados de teores de N total (g kg^{-1}) por modelos LASSO, enquanto o gráfico da FIGURA 1d) exibe os valores de N total preditos por modelos PLS. As métricas obtidas foram melhores nos modelos PLS que nos modelos LASSO.



Gráficos de dispersão entre valores preditos e observados de COS (nos gráficos a e b) e N total (nos gráficos c e d) das amostras de solo: pontos representam a média das predições, enquanto a linha horizontal a amplitude de predições, para uma mesma amostra do conjunto de teste. Os gráficos a e c) exibem predições dos modelos LASSO, enquanto os gráficos b e d) exibe predições dos modelos PLS.

Verificou-se que não houve diferença estatística significativa entre o CCC obtido na modelagem com PLS e LASSO para teores de COS (TABELA 1). No entanto, no caso da predição de teores de N total, verificou-se que há diferença significativa entre o ajuste obtido com modelos PLS em relação ao LASSO.

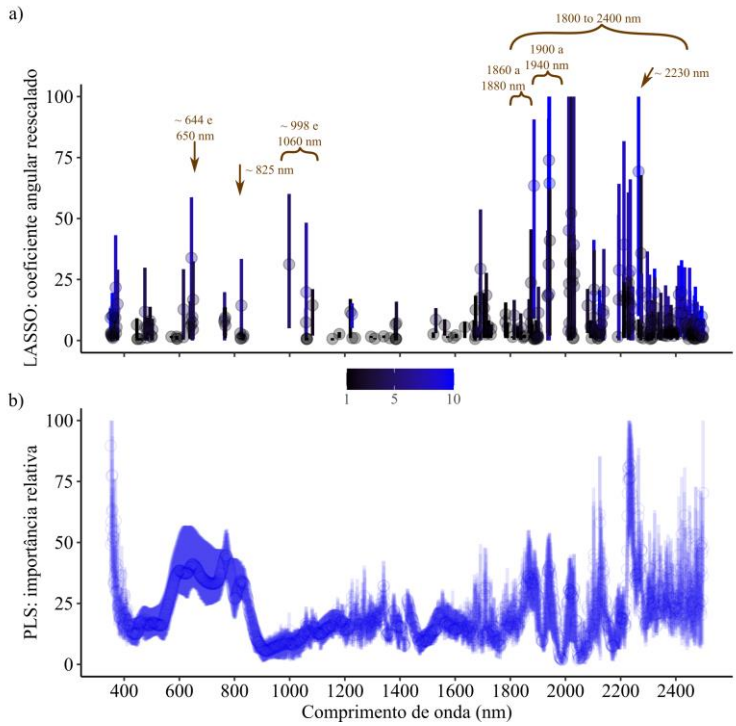
Tendo em vista a boa performance dos modelos, a FIGURA 2 exibe os gráficos de importância das bandas espectrais Vis-NIR-SWIR na modelagem de COS. O LASSO selecionou entre 77 e 97 bandas espectrais (de 2151). As bandas espectrais com maior importância selecionadas pelo LASSO (destacadas na FIGURA 2b) são intrinsecamente relacionadas aos teores de COS: feições associadas à MO em 650 e 825 nm, além de bandas no SWIR (de 1800 a 2400 nm) apresentam assinaturas

espectrais de compostos orgânicos como aminas, alquis, ácidos carboxílicos (especialmente entre 1900 e 1940 nm), amidas, compostos alifáticos, metis, compostos fenólicos, polissacarídeos e carboidratos (VISCARRA ROSSEL; BEHRENS, 2010). Além disso, há bandas relacionadas à presença de óxidos de ferro (em aproximadamente 520 e 650 nm) e a argilominerais (como a região de 2230 nm, associada a presença de hidróxidos de alumínio) (VISCARRA ROSSEL; BEHRENS, 2010). Bandas com menor importância selecionadas pelo LASSO se devem à não-colinearidade destas (BRICKLEMYER et al., 2018).

TABELA 1. Resultado do teste de Mann-Whitney para o CCC.

Método de regressão	CCC na predição de teores de COS		CCC na predição de teores de N total	
	x	sd	x	sd
PLS	0.777 a	0.078	0.787 a	0.063
LASSO	0.775 a	0.062	0.678 b	0.063
p-valor*	0.8534		0.002879	
Estatística do teste	35		88	

x e sd são a média e o desvio padrão, respectivamente, dos valores observados para a métrica CCC após modelagem com cada método de regressão. * Médias seguidas de mesmas letras minúsculas nas colunas não diferem (P = 0.05).



Gráficos de importância das bandas espectrais usadas na predição dos teores de COS. O gráfico em a) mostra a importância para os modelos LASSO, em que os pontos representam o valor médio e a linha vertical a amplitude (valor mínimo e máximo) de importância das bandas; a cor representa o número de vezes que a banda foi selecionada/usada (entre as 10 repetições). O gráfico em b) exibe o espectro de importância relativa das covariáveis usadas pelo PLS.

Embora o PLS performou melhor para predizer N total, o RMSE obtido com o LASSO está, também, dentro do esperado na literatura, cujos melhores resultados encontrados são da ordem de 0.19 a 0.48

g kg-1 (SANTOS et al., 2020). Além disso, as bandas espectrais selecionadas pelo LASSO são elusivas aos compostos nitrogenados na MO. Foram selecionadas entre 43 e 64 bandas espectrais (de 2151) o de N total, dentre elas, algumas são diretamente relacionadas à MO, como as bandas no infravermelho em 1400, 1900 e 2260 nm. Houve também bandas associadas aos compostos alifáticos, grupos de amidas e aminas (VISCARRA ROSSEL; BEHRENS, 2010).

A confiabilidade das estimativas de modelos de espectroscopia de solos é uma demanda recente, pois, esse tipo de metodologia tem se tornado uma tecnologia (SAFANELLI et al., 2023). Por isso a habilidade de identificar relação causal existente entre a reflectância e a os atributos do solo é importante (MCBRIDE, 2022). Desse modo, métodos como o LASSO podem produzir estimativas equiparáveis aos mais complexos métodos de ML, tendo a vantagem de produzir modelos mais transparentes.

CONCLUSÃO

Os modelos LASSO foram melhores que os modelos PLS para predizer teores de SOC. Já no caso da modelagem de N total, os modelos PLS foram melhores. Contudo, apesar do desempenho do PLS para predizer teores de N, em todos os casos o LASSO tem a vantagem da transparência intrínseca dos modelos. Com isso, foi possível analisar diretamente a relação entre bandas espectrais no Vis-NIR-SWIR usadas na modelagem.

AGRADECIMENTOS

À Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), pelo Processo APQ-01562-23.

REFERÊNCIAS

ANGELOPOULOU, T. et al. From Laboratory to Proximal Sensing Spectroscopy for Soil Organic Carbon Estimation-A Review. Sustainability, v. 12, n. 2, p. 443, jan. 2020.

CANTARELLA, H. Nitrogênio. Em: Fertilidade do Solo. Viçosa: Sociedade Brasileira de Ciência do Solo, 2007. p. 1017.

DEMATTÊ, J. A. M. et al. Soil analytical quality control by traditional and spectroscopy techniques: Constructing the future of a hybrid laboratory for low environmental impact. Geoderma, v. 337, p. 111-121, 1 mar. 2019.

DOS SANTOS, E. P. et al. Improving the generalization error and transparency of regression models to estimate soil organic carbon using soil reflectance data. Ecological Informatics, v. 77, p. 102240, 1 nov. 2023.

GREENWELL, B. M.; BOEHMKE, B. C. Variable Importance Plots-An Introduction to the vip Package. The R Journal, v. 12, n. 1, p. 343, 2020.

MCBRIDE, M. B. Estimating soil chemical properties by diffuse reflectance spectroscopy: Promise versus reality. European Journal of Soil Science, v. 73, n. 1, p. e13192, 2022.

SAFANELLI, J. L. et al. An interlaboratory comparison of mid-infrared spectra acquisition: Instruments and procedures matter. Geoderma, v. 440, p. 116724, 1 dez. 2023.

SANTOS, U. J. DOS et al. Predicting carbon and nitrogen by visible near-infrared (Vis-NIR) and mid-infrared (MIR) spectroscopy in soils of Northeast Brazil. Geoderma Regional, v. 23, p. e00333, 1 dez. 2020.

VISCARRA ROSSEL, R. A.; BEHRENS, T. Using data mining to model and interpret soil diffuse reflectance spectra. Geoderma, Diffuse reflectance spectroscopy in soil science and land resource assessment. v. 158, n. 1, p. 46-54, 15 ago. 2010.

WIESMEIER, M. et al. Soil organic carbon storage as a key function of soils - A review of drivers and indicators at various scales. Geoderma, v. 333, p. 149-162, 1 jan. 2019.

MAPEAMENTO DE ATRIBUTOS DE SOLO COM SENSOR INTELIGENTE

BEATRIZ REGINA DA SILVA SANTOS [3]; MARIA ELOYSE GONÇALVES LUIZ [3]; AMÉLIA LAÍSY DO NASCIMENTO [1]; DANIEL MARÇAL DE QUEIROZ [2]; EMANOEL DI TARSO DOS SANTOS SOUSA [1]

[1]Professor. Rua Dom Manuel de Medeiros, s/n, Dois Irmãos - CEP: 52171-900 - Recife/PE. Universidade Federal Rural de Pernambuco; [2]Professor. Avenida PH Rofls, s/n, Viçosa -MG. Universidade Federal de Viçosa; [3]Estudante. Rua Dom Manuel de Medeiros, s/n, Dois Irmãos - CEP: 52171-900 - Recife/PE. Universidade Federal Rural de Pernambuco

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A tarefa de mapear solos custa caro e uma alternativa a essa problemática é o uso de sensores. Este estudo teve como objetivo testar um sensor inteligente no mapeamento de solo. A coleta de dados foi realizada na Universidade Federal Rural de Pernambuco e seguiu uma amostragem sistematizada. Os mapas foram obtidos por meio da krigagem ordinária realizada no plugin Smart-Map do QGIS. Os resultados obtidos indicam um bom funcionamento do sensor testado e coerência nos dados adquiridos com este.

PALAVRAS-CHAVE: Variabilidade Espacial; Krigagem Ordinária; Smart-Map

ABSTRACT

The task of mapping soil is expensive and an alternative to this problem is the use of sensors. This study aimed to test a smart sensor in soil mapping. Data collection was carried out at the Federal Rural University of Pernambuco and followed a systematic sampling. The maps were obtained through ordinary kriging performed in the QGIS Smart-Map plugin. The results obtained indicate good functioning of the tested sensor and coherence in the data acquired with it.

KEYWORDS: ;

INTRODUÇÃO

Na agricultura de precisão a detecção da variabilidade espacial é essencial para uma tomada de decisão assertiva. No entanto, sabe-se que o custo de amostragem de solo é alto para se obter dados espaciais detalhados. Nesse sentido, o uso de sensoriamento de solo é uma alternativa viável para o mapeamento de solos. Com isso, os sensores de condutividade elétrica aparente do solo se mostram relevantes na detecção da variabilidade dos solos já que suas leituras apresentam correlação com os atributos do solo. Dessa forma, é essencial que mais alternativas desse tipo de sensor sejam desenvolvidas e difundidas. Sendo assim, o presente trabalho teve como objetivo testar um multisensor de solo no mapeamento de condutividade elétrica aparente, temperatura e umidade do solo.

OBJETIVOS

O presente trabalho teve como objetivo testar um multisensor de solo no mapeamento de condutividade elétrica aparente, temperatura e umidade do solo.

MATERIAL E MÉTODOS

Os dados de condutividade elétrica aparente, temperatura e umidade do solo foram coletados em campo de futebol existente nas dependências da Universidade Federal Rural de Pernambuco em uma área de aproximadamente 0,4ha. A referida área apresenta solo de textura arenosa e se encontrava seco no momento da coleta. O sensor utilizado para o levantamento foi o *Smart-Sensor* (Figura 1 - A), desenvolvido por pesquisadores da Universidade Federal de Viçosa, e que é capaz de mensurar todas as variáveis mencionadas anteriormente (QUEIROZ et al., 2020, SOUSA et al., 2021; SOUSA et al., 2023). No total foram adotados 52 pontos de leitura com cinco repetições em cada um desses pontos. A amostragem seguiu esquema sistematizado, com espaçamento médio de 8 metros entre os pontos de coleta (Figura 1 - B). Os mapas de variabilidade espacial foram obtidos por meio do *plugin Smart-Map* do programa de computador QGIS versão 3.36 (PEREIRA et al., 2022). O método de interpolação utilizado foi a krigagem ordinária. Para cada variável foram escolhidos os modelos teóricos de semivariâcia que apresentaram menor RMSE e maior R^2.

A) B)



FIGURA 1. A - *Smart-Sensor* utilizado na coleta de dados, B - Distribuição dos pontos amostrais na área de estudo.

RESULTADOS E DISCUSSÃO

Os mapas de condutividade elétrica aparente, temperatura do solo e umidade do solo apresentaram padrão espacial similar entre si (Figura 2). Percebe-se que as regiões que apresentaram maior teor de água também apresentaram maiores valores de condutividade elétrica aparente (SOUSA et al., 2023). Esse resultado indica a coerência dos dados obtidos, uma vez que a condutividade elétrica aparente tem correlação positiva com a umidade do solo (QUEIROZ et al., 2020). Já os valores de temperatura observados foram maiores em locais que a umidade e condutividade elétrica aparente foram menores.

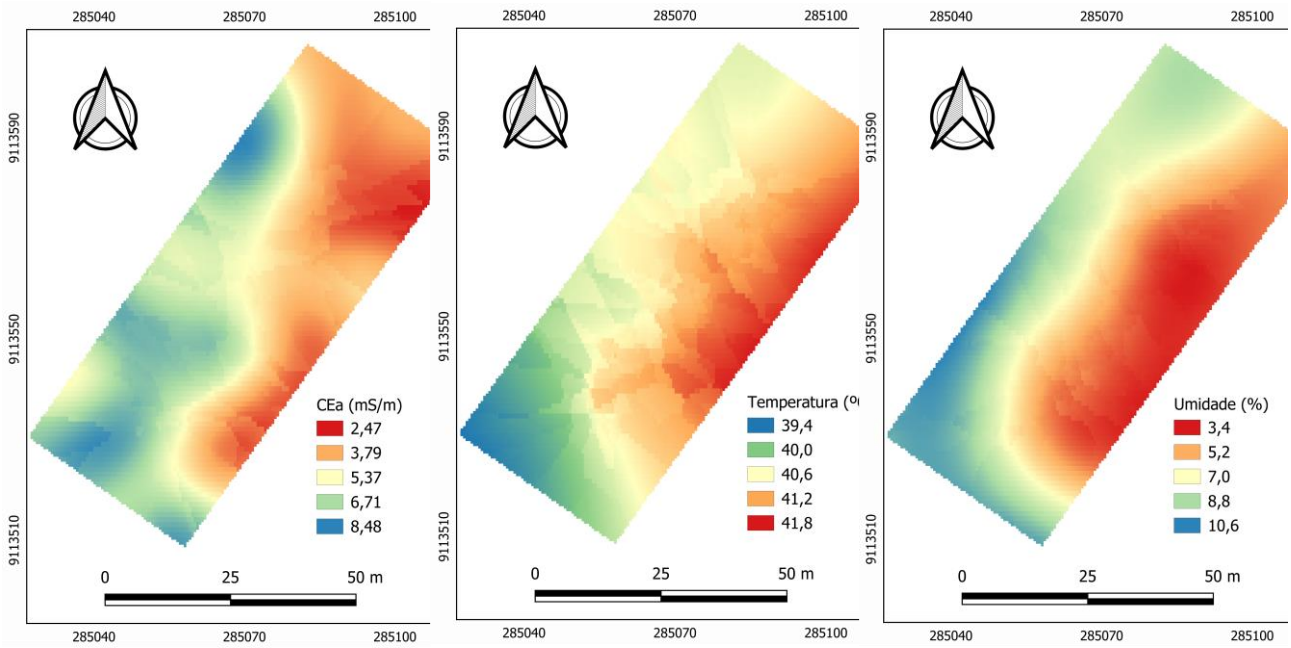


FIGURA 2. Mapas de variabilidade espacial elaborados com os dados obtidos com o *Smart-Sensor*.

A partir dos resultados apresentados na Tabela 1, podemos perceber que os dados obtidos com o *Smart-Sensor* foram capazes de representar bem a variabilidade espacial da condutividade elétrica aparente, temperatura e umidade do solo. Isso por que os alcances obtidos na análise de semivariância foram todos superiores a distância média entre os pontos amostrais.

TABELA 1. Parâmetros teóricos de semivariância ajustados no *plugin Smart-Map* do QGIS para os dados experimentais obtidos com o *Smart-Sensor*.

Variável	Modelo	Alcance	RMSE	R^2
CEa	Exponencial	26,72	4,056	0,76
Temperatura do solo	Linear com patamar	54,57	0,127	0,84
Umidade do solo	Gaussian	37,59	1,359	0,97

CONCLUSÃO

O *Smart-Sensor* funcionou bem durante toda a aquisição de dados. A variabilidade espacial das variáveis obtidas com o *Smart-Sensor* foi determinada com sucesso.

AGRADECIMENTOS

Os autores do presente trabalho agradecem ao Conselho Nacional de Pesquisa e Desenvolvimento (CNPq) pelo apoio financeiro para a realização da pesquisa por meio do Processo: 404374/2021-2, da chamada CNPq/MCTI/FNDCT No 18/2021, Título: "Desenvolvimento de um sistema inteligente para caracterização da variabilidade espacial do solo em agricultura de precisão".

REFERÊNCIAS

PEREIRA, G. W.; VALENTE, D. S. M.; QUEIROZ, D. M. D.; COELHO, A. L. D. F.; COSTA, M. M.; GRIFT, T. Smart-map: an open-source QGIS plugin for digital mapping using machine learning techniques and ordinary kriging. **Agronomy**, v. 12, n. 6, p. 1350, 2022.

QUEIROZ, D. M.; SOUSA, E. D. T. S; LEE, W. S.; SCHUELLER, J. K. Development and testing of a low-cost portable apparent soil electrical conductivity sensor using a beaglebone black. **Applied Engineering in Agriculture**, v. 36, n. 3, p. 341-355, 2020.

SOUSA, E. D. T. S.; QUEIROZ, D. M.; COELHO, A. L. F.; VALENTE, D. S. M. Development of signal analysis algorithm for apparent soil electrical conductivity sensor. **Biosystems Engineering**, v. 211, 183-191, 2021.

SOUSA, E. D. T. S.; QUEIROZ, D. M.; COELHO, A. L. F.; VALENTE, D. S. M. Development of a portable multisensor platform for soil mapping. **Revista Ciência Agronômica**, v. 54, p. e20217886, 2023.

VARIABILIDADE ESPACIAL/INTERANUAL DO QUOCIENTE FOTOTERMAL NO SUL DO BRASIL E SEU IMPACTO NO POTENCIAL DE RENDIMENTO DO TRIGO

Gilberto Rocca da Cunha [3]; Grazieli Rodigheri [1]; Aldemir Pasinato [3]; João Leonardo Fernandes Pires [3]; Jordano Bortoncello [2]

[1]Doutoranda. São José dos Campos ? SP.. Instituto Nacional de Pesquisas Espaciais; [2]Bolsista PIBIC/CNPq Embrapa Trigo. Campus - Sertão, RS. Instituto Federal do Rio Grande do Sul ; [3]Analista/Pesquisador. Rodovia BR 285, km 294 - 99050970 - Passo Fundo, RS. Empresa Brasileira de Pesquisa Agropecuária (Embrapa Trigo)

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A oferta ambiental, mensurada pelo quociente fototermal (Qf), define o potencial de rendimento do trigo. A variabilidade de Qf, no período crítico de 30 dias (20 antes e 10 depois da antese), pode explicar as diferenças intrarregionais e interanuais no desempenho produtivo desse cereal no sul do Brasil. Os anos de 2022 e 2023, ano de La Niña e de El Niño, respectivamente, exemplificam que estresses de natureza biótica e abiótica, na escala interanual, podem se sobrepor à oferta ambiental, valores de Qf, com efeitos negativos sobre o potencial de rendimento de grãos do trigo no sul do Brasil.

PALAVRAS-CHAVE: *Triticum aestivum L*.; El Niño; La Niña

ABSTRACT

The environmental availability, measured by the photothermal quotient (Qf), determines the yield potential of wheat. The variability of Qf during the critical 30-day period (20 days before and 10 days after anthesis) can explain the intra-regional and interannual differences in the productive performance of this cereal in southern Brazil. The years of 2022 and 2023, characterized by La Niña and El Niño events respectively, exemplify that biotic and abiotic stresses at an interannual scale can overlap the environmental supply as indicated by Qf values, thereby negatively impacting the wheat grain yield potential in southern Brazil.

KEYWORDS: *Triticum aestivum L*.; El Niño; La Niña

INTRODUÇÃO

O Sul do Brasil é a principal região produtora de trigo do País, com destaque para os estados do Rio Grande do Sul e do Paraná, que contabilizam mais de 80% da produção nacional (Conab, 2024). Todavia, nas escalas intrarregional e interanual, os ambientes de produção desse cereal, em geral, se diferenciam nos rendimentos que são obtidos tanto em lavouras quanto em experimentos. A razão para tal, além dos estresses bióticos e abióticos e das diferenças nas práticas de manejo dos cultivos que definirão o resultado da interação Genótipo x Ambiente x Manejo (G x A x M), reside na variabilidade da oferta ambiental, que, no caso do potencial de rendimento de grãos de trigo, pode ser mensurada pelo quociente fototermal (relação radiação solar/temperatura).

São muitas as evidências, na literatura, indicando que o número de grãos por unidade de área (mais do que o peso individual dos grãos) é o componente numérico que, na ausência de outros fatores limitantes, explica a maior parte da variabilidade do potencial de rendimento do trigo (FISCHER, 1985; SLAFER et al., 2022; entre outros). É bem conhecida, desde o trabalho seminal de Fischer (1985), a existência de uma relação positiva entre o quociente fototermal, no período crítico de 30

dias (20 antes e 10 depois da antese), e a definição do número de grãos por unidade de área nesse cereal. Evidentemente, não podem ser ignoradas as relações de troca, seja por força de variabilidade do ambiente físico, pelas caraterísticas intrínsecas dos genótipos (cultivares) ou por decisões de manejo, que são passíveis de afetar os componentes numéricos (número de espigas por unidade de área e número de grãos por espiga) ou fisiológicos (massa seca da espiga na antese e eficiência na fecundação das flores e formação de grãos), que, em última instância, acabam se refletindo no número de grãos por unidade de área, que é o principal componente do rendimento de uma lavoura de trigo.

OBJETIVOS

O objetivo deste trabalho foi avaliar, nas escalas regional e interanual (associada com as fases do fenômeno ENOS), a variabilidade espacial do quociente fototermal e seu impacto no potencial de rendimento de grãos do trigo no sul do Brasil.

MATERIAL E MÉTODOS

Na análise do impacto do quociente fototermal (Qf) no potencial do rendimento de grãos do trigo, foram utilizados dados satelitais, e, para análise na escala intrarregional, variáveis medidas em estações meteorológicas de superfície e resultados de experimentos de trigo, conduzidos nos anos 2022 (La Niña) e 2023 (El Niño), em diferentes locais do sul do Brasil.

As imagens compostas a partir de produtos satelitais, dados observados e de reanálise foram obtidas do European Centre for Medium-Range Weather Forecast (ECMWF) por meio da plataforma Google Earth Engine (GEE). Foram utilizados os produtos de temperatura do ar e de radiação solar global do ERA5 (HERSBACH, et al., 2020). O produto de temperatura selecionado corresponde à temperatura a 2 m acima da superfície da terra, mar ou águas interiores, enquanto que o de radiação solar global compreende a quantidade de radiação solar direta e difusa que atinge a superfície da terra e é equivalente ao que seria medido por um piranômetro na superfície. Ambos os produtos têm resolução espacial de 0,25° (equivalente a 31 quilômetros) e resolução temporal diária.

As imagens de temperatura foram convertidas de Kelvin para graus Celsius (°C = K - 273,15), e as imagens de radiação, de J m^{-2} para MJ m^{-2}.

O cálculo do quociente fototermal (Qf) foi realizado com base no modelo proposto por FISCHER (1985), para os anos e período selecionados (30 dias críticos entre 15 de agosto e 15 de setembro), por meio da equação: Qf = Rs/T - 4,5, onde Qf é o quociente fototermal ($MJ.m^{-2}.dia^{-1}.°C^{-1}$), Rs é a radiação solar global ($MJ.m^{-2}.dia^{-1}$) e T é a temperatura média diária (°C). A partir dos dados diários, foram calculados os quocientes fototermais médios diários, para o período de 30 dias.

Os dados de rendimento de grãos de trigo foram obtidos da Rede de Ensaios conduzida em diferentes locais na Região Sul, composta por ensaios de competição de 30 cultivares comerciais (Ensaio Estadual de Cultivares de Trigo - EECT) mais utilizadas no RS e, também, pelos ensaios de Valor de Cultivo e Uso (VCU) para avaliação de linhagens de trigo. O delineamento foi de blocos casualizados com três ou quatro repetições, seguindo metodologia específica, e com práticas de manejo não limitantes ao potencial produtivo (REUNIÃO..., 2023).

RESULTADOS E DISCUSSÃO

Na Figura 1, utilizando-se como referencial o mapeamento do Qf, centrado em 15 de setembro, que representaria a maioria das lavouras de trigo do sul do Brasil (sul do PR, SC e RS, principalmente), comparando os anos 2022 e 2023, ficam bem evidenciados os contrastes intrarregionais e interanual

(La Niña X El Niño) dessa variável, que, em tese, independente de outros fatores limitantes, tem reflexos no potencial de rendimento de grãos do trigo.

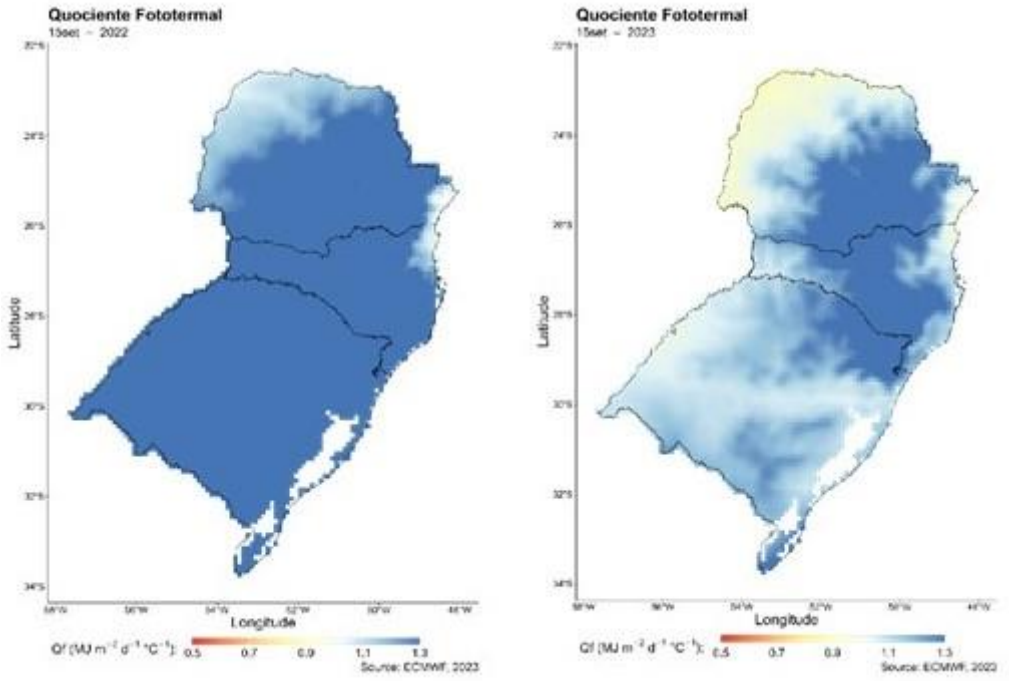


FIGURA 1. Quociente fototermal (Qf_30dias), 15 de setembro, no Sul do Brasil, em anos de extremos de oferta ambiental (2022: elevada x 2023: baixa).

Os resultados de experimentos de trigo, que foram conduzidos em diferentes locais (Figura 2), nas safras 2022 e 2023, corroboram o impacto da oferta ambiental (Figura 3), evidenciado na Figura 1.

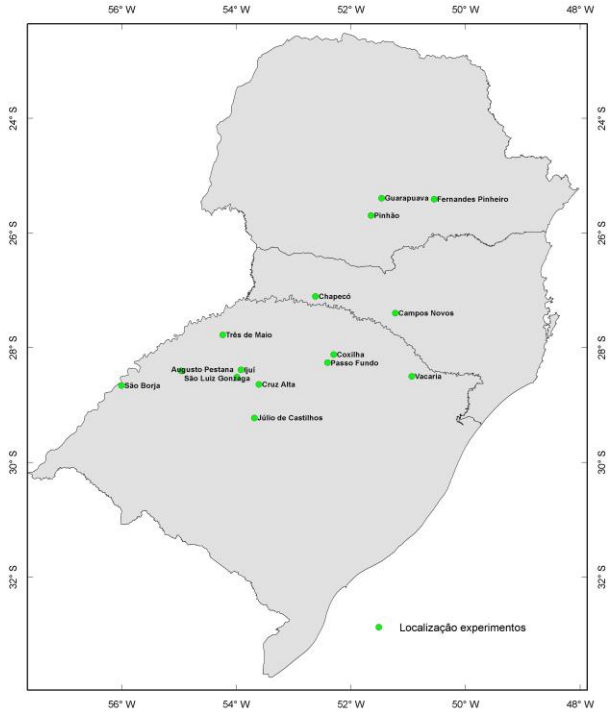


FIGURA 2. Localização dos experimentos de trigo conduzidos nas safras 2022 e 2023, no sul do Brasil.

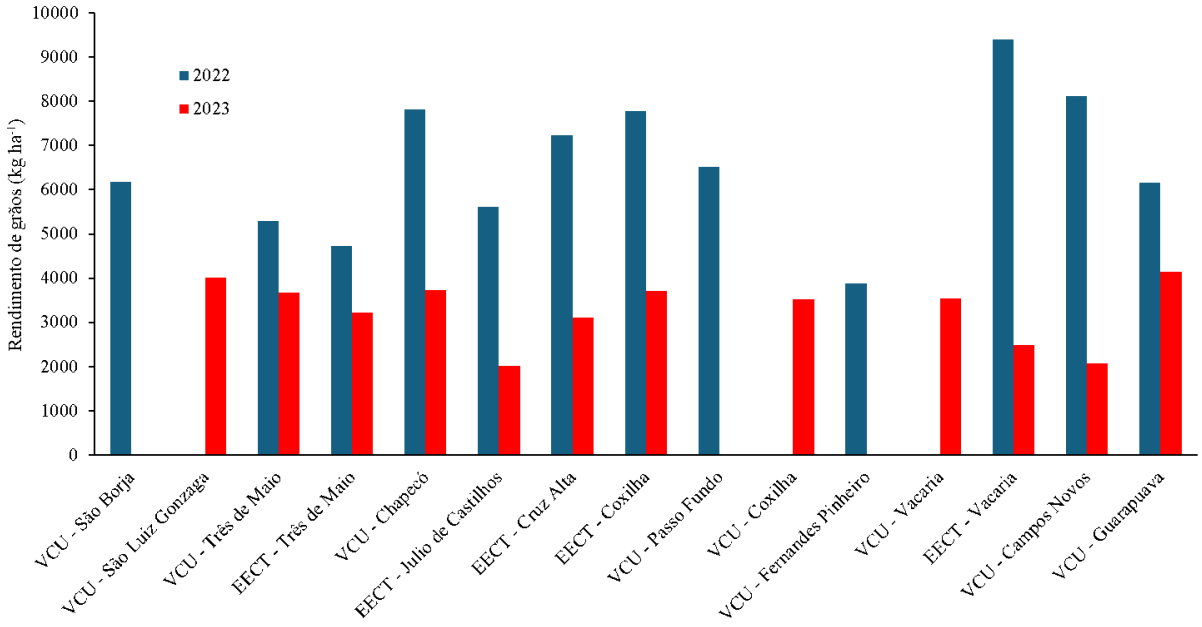


FIGURA 3. Rendimento de grãos de trigo (média de 30 cultivares) em diferentes locais da Região Sul do Brasil em anos de extremos de oferta ambiental (2022: elevada x 2023: baixa). VCU: Valor de Cultivo e Uso; EECT: Ensaio Estadual de Cultivares de Trigo.

A variabilidade no Qf, intrarregionalmente, apesar de ser condicionante principal do potencial de rendimento de grãos em trigo no sul do Brasil (CUNHA et al., 2005), não determina, por si só, o rendimento de grãos obtidos nas lavouras. Isso fica evidente quando se observa a região leste do RS e SC em 2023 (Figura 1). Mesmo com o Qf maior que as demais regiões (indicando uma oferta ambiental elevada para plantas), o rendimento de grãos de trigo obtidos nos ensaios foi menor do que nos locais da faixa oeste destes estados (Figuras 2 e 3). Por meio do acompanhamento dos ensaios, foi verificado que o excesso de chuvas e temperaturas mais elevadas que a normal climatológica (dados não mostrados), especialmente nos períodos de espigamento/florescimento e enchimento de grãos, acarretaram maior incidência e severidade de doenças de espiga (giberela e brusone) que acabaram por reduzir drasticamente o rendimento de grãos na aludida safra. O reflexo da diferença na oferta ambiental, dos valores de Qf e dos impactos dos estresses causados pelas variáveis meteorológicas pode ser constatado nas estatísticas de rendimento de trigo nos três estados da Região Sul, registradas nas safras 2022 e 2023 (CONAB, 2024): RS (3.941 x 1.930 kg.ha^{-1}) SC (3.418 x 2.150 kg.ha^{-1}) e PR (2.928 x 2.560 kg.ha^{-1}).

CONCLUSÃO

- A variabiliabidade intrarregional da oferta ambiental, valores de Qf, pode explicar diferenças no potencial de rendimento de grãos do trigo no sul do Brasil.
- Estresses de natureza biótica e abiótica, na escala interanual, podem se sobrepor à oferta ambiental, valores de Qf, afetando negativamente o potencial de rendimento de grãos do trigo no sul do Brasil.

REFERÊNCIAS

CONAB - Companhia Nacional de Abastecimento. Séries Históricas das Safras. Grãos. Trigo. Disponível em: <https://www.conab.gov.br/info-agro/safras/serie-historica-das-safras/itemlist/category/913-trigo>. Acesso em: 20 agosto 2024.

CUNHA, G. R.; PIRES, J. L. F.; PASINATO, A.; DALMAGO, G. A. Variabilidade temporal e espacial do quociente fototermal no Rio Grande do Sul e suas implicações para a expressão do potencial de rendimento de grãos de trigo. **Revista Brasileira de Agrometeorologia**, v. 13, n. 1, p. 91-101, 2005.

FISCHER, R. A. Number of kernels in wheat crops and the influence of solar radiation and temperature. **Journal of Agriculture Science**, v. 105, p. 447-461, 1985.

HERSBACH, H.; BELL, B.; BERRISFORD, P. et al. The ERA5 global reanalysis. **QJR Meteorol. Soc**., v. 146, p. 1999-2049, 2020. DOI: 10.1002/qj.3803

REUNIÃO DA COMISSÃO BRASILEIRA DE PESQUISA DE TRIGO E TRITICALE, 15., 2022, Brasília, DF. **Informações técnicas para trigo e triticale**: safra 2023. Gilberto Rocca da Cunha, Eduardo Caierão, editores técnicos. Brasília, DF: Embrapa, 2023. 142 p.

SLAFER, G. A.; GARCÍA, G. A.; SERRAGO, R. A.; MIRALLES, D. J. Physiological drivers of responses of grains per m^2 to environmental and genetic factors in wheat. **Field Crops Research,** 285 (2022) 108593. DOI: 10.1016/j.fcr.2022.108593.

PREDIÇÃO DE PRODUTIVIDADE DA BATATA INGLESA A PARTIR DE SENSORIAMENTO REMOTO ORBITAL

Samira Luns Hatum de Almeida [1]; Jarlyson Brunno Costa Souza [2]; Bruno Ripa Baptista [3]; Vinicius dos Santos Carreira [2]; Rouverson Pereira da Silva [4]

[1]Pós-doutoranda. Via de Acesso Professor Paulo Donato Castelane Castellane. Universidade Estadual Paulista 'Júlio de Mesquita Filho; [2]Doutorando. Via de Acesso Professor Paulo Donato Castelane Castellane. Universidade Estadual Paulista 'Júlio de Mesquita Filho; [3]Graduando. Via de Acesso Professor Paulo Donato Castelane Castellane. Universidade Estadual Paulista 'Júlio de Mesquita Filho; [4]Docente. Via de Acesso Professor Paulo Donato Castelane Castellane. Universidade Estadual Paulista 'Júlio de Mesquita Filho

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A busca pela garantia alimentar impulsiona o desenvolvimento de estudos com alimentos que são considerados a base da alimentação humana, como o caso da batata. Nesse sentido, entender a dinâmica de produção auxilia a tomada de decisão para estratégias mais assertivas, visando agregar qualidade ao produto e evitar perdas ao longo da cadeia produtiva. Dito isso, objetivou-se com este trabalho estimar a produtividade da batata inglesa por meio de redes neurais artificiais aplicadas ao sensoriamento remoto orbital. Para isso, amostras foram coletadas em uma área comercial de batata inglesa (variedade Ágata) em um grid de 100 pontos e analisadas em termos de produtividade total e comercial. Realizou-se aquisição de imagens da reflectância da superfície PlanetScope da lavoura aos 40 dias após plantio (DAP), 55, 70 e 85 DAP, foram calculados três índices de vegetação: NDVI, NDRE e GNDVI e extraídos os dados nos pontos de interesse. Para estimar a produtividade da lavoura, foram utilizados dois tipos de Redes Neurais Artificiais: RBF e MLP, com treinamento em 80% dos dados e teste em 20%. A eficácia dos modelos foi avaliada por meio do erro médio absoluto (MAE). Os modelos gerados a partir dos índices aos 40 DAP com a rede MLP foram os que apresentaram melhor acurácia para a produtividade total e comercial da batata, com MAE de 4,13 e 4,60 t/ha, respectivamente.

PALAVRAS-CHAVE: Agricultura Digital; Colheita Inteligente; Redes Neurais Artificiais

ABSTRACT

The pursuit of food security drives the development of studies on staple foods such as potatoes, which are considered fundamental to human nutrition. Understanding production dynamics aids in making more accurate decisions, aiming to enhance product quality and prevent losses throughout the production chain. In this context, the objective of this study was to estimate potato productivity using artificial neural networks applied to orbital remote sensing. Samples were collected from a commercial potato field (Ágata variety) in a grid of 100 points and analyzed in terms of total and commercial productivity. Reflectance images of the crop surface were acquired using PlanetScope at 40, 55, 70, and 85 days after planting (DAP), and three vegetation indices were calculated: NDVI, NDRE, and GNDVI. Data were extracted at the points of interest. To estimate crop productivity, two types of Artificial Neural Networks were used: RBF and MLP, with training on 80% of the data and testing on 20%. The effectiveness of the models was evaluated using the mean absolute error (MAE). The models generated from the indices at 40 DAP using the MLP network showed the best accuracy for total and commercial potato productivity, with MAE of 4.13 and 4.60 t/ha, respectively.

KEYWORDS: ;;

INTRODUÇÃO

A modernização da agricultura tem fornecido estratégias que buscam tornar a atividade mais sustentável, e capaz de suprir a demanda cada vez maior de alimento. Diante de um cenário de aumento populacional, garantir segurança alimentar é fundamental para o futuro das próximas gerações, sendo esse um dos Objetivos de Desenvolvimento Sustentável (ODS) da ONU.

Nesse sentido, é de suma importância avançar em estudos de alimentos que são a base da alimentação humana, como a batata (*Solanum tuberosum* L.), quarto alimento mais consumido no mundo (Li et al., 2020). Compreender a produtividade da batata contribui com o planejamento de várias etapas da cadeia produtiva, desde entender a variabilidade espacial da lavoura para correto manejo até o pós-colheita, que inclui transporte e beneficiamento do produto.

O processo mais usual de estimar a produtividade de culturas agrícolas é de forma manual, o que é moroso e demanda tempo. As novas tecnologias atreladas a agricultura digital, como o sensoriamento remoto e a inteligência artificial tem alto potencial para estimar a produtividade de forma não destrutiva e mais eficiente.

Na cultura da batata, estudos têm sido desenvolvidos nesse sentido, entretanto apresentam dificuldades de implementação às condições brasileiras. Gomes et al. (2019) utilizou imagens do satélite Sentinel- 2. Por mais que sejam imagens gratuitas, a presença de nuvens no período da safra de verão da batata no Brasil prejudica a disponibilidade de imagens, e compromete o uso do modelo proposto. Optar por satélites com melhor resolução temporal, como o PlanetScope pode ser uma forma de tornar a predição de produtividade da batata mais aplicável e usual.

OBJETIVOS

Objetivou-se com este trabalho, em condições específicas da safra do ano de 2024, utilizar sensoriamento remoto orbital de alta resolução temporal, juntamente a algoritmos de inteligência artificial, para a obtenção de modelos iniciais mais precisos e acurados de predição da produtividade de batata inglesa.

MATERIAL E MÉTODOS

O experimento foi conduzido em área comercial cultivada com batata inglesa, variedade Ágata, no município de Porto Ferreira - SP. A cultura foi implementada dia 10 de maio de 2023, e a dessecação por volta do dia 5 de agosto. No dia 23 de agosto, previamente à colheita da cultura, foram realizadas avaliações da produtividade da lavoura.

As amostras foram coletadas em malha regular de 100 pontos, no qual foram espaçadas em 25 metros. Em cada ponto amostral foi posicionada uma armação de 2 metros quadrados (1,8 x 1,1 m). As batatas foram retiradas da amontoa com o auxílio da enxada e colocadas em saco de estopa. Cada uma das amostras foi pesada, e separada quanto ao diâmetro em batatas comerciais e não comerciais. Dessa forma, a partir de cada amostra, obtiveram-se duas variáveis: produtividade total e produtividade comercial, em toneladas/hectare.

Para as predições, foram utilizados dados de sensoriamento remoto orbital, obtidas a partir da Constelação de satélites PlanetScope. As imagens em questão são da reflectância da superfície, possuem resolução espacial de 3 metros, e são compostas por quatro bandas, sendo elas azul (455-515 nm), verde (500-590 nm), vermelho (590-570nm) e infravermelho próximo (780-860 nm).

Foram selecionadas imagens de quatro etapas do desenvolvimento da cultura: 40 dias após plantio (DAP), e as demais, de um intervalo de 15 dias (55 DAP, 70 DAP, 85 DAP).

Após a aquisição das imagens, estas foram processadas em software GIS de acesso gratuito. Como as imagens PlanetScope são disponibilizadas em GeoTIFF de 16 bits com valores de refletância dimensionados em 10.000, foi necessário transformá-las para escala de 0 a 1, por meio da calculadora raster. A etapa seguinte consistiu em calcular os índices de vegetação pela calculadora raster: Índice de Vegetação da Diferença Normalizada (NDVI); Índice de Vegetação da Diferença Normalizada da Borda do Vermelho (NDRE); e o Índice de Vegetação da Diferença Normalizada Verde (GNDVI), conforme apresentado nas equações a seguir:

Em que: α8, α7, α6, α4: reflectância nas bandas do infravermelho próximo, borda do vermelho, vermelho, e verde, respectivamente.

De posse dos Índices de Vegetação para as quatro datas, os dados foram extraídos dos 100 pontos amostrais, a partir de um buffer quadrado de 5 m de lado gerado a partir de cada ponto amostral, por meio da ferramenta Estatística Zonal.

Para obtenção de modelos de predição serão usados dois algoritmos de Redes Neurais Artificiais (RNA), do tipo função de ativação de base radial (RBF) e perceptron de multicamadas (MLP), ambos de aprendizado supervisionado. As RNA's são uma ferramenta da inteligência artificial, cujo objetivo é aprender relações entre variáveis e reconhecer padrões por meio de exemplos, e assim desenvolver modelos não lineares (Savegnago et al 2011; Soares et al., 2015). A rede neural perceptron multicamadas (MLP) é treinada com entradas ajustadas à variável de saída, em duas fases, a forward e a backward. O software utilizado foi o Statistica 7. Para o treinamento e validação dos modelos, o banco de dados foi divido em 80% dos dados para o treinamento e 20% dos dados para validação (Silva et al., 2016). Na fase de treinamento, as RNA's foram treinadas dez mil vezes cada modelo, pois os parâmetros livres são obtidos de forma aleatória (Soares et al., 2014). A eficiência dos modelos gerados foi analisada por meio de gráficos de desempenho com a relação 1:1 (Soares et al., 2014) em que serão calculados em termos de acurácia e precisão o erro médio absoluto (MAE).

RESULTADOS E DISCUSSÃO

Os modelos de redes neurais MLP (Perceptron Multicamadas) e RBF (Radial Basis Function) foram aplicados para estimar o peso total e o peso comercial das batatas. A Figura 1 ilustra gráficos de linha comparando os valores observados e estimados para esses dois tipos de redes neurais. De maneira geral é possível observar que os valores observados apresentaram alta variabilidade o que tornou a precisão dos modelos baixa. Desta forma, o algoritmo que apresentou o melhor ajuste foi o peso comercial para a rede neural RBF.

A Tabela 1 detalha os erros de predição dos modelos para o peso total e comercial das batatas. O modelo MLP teve um erro absoluto médio (MAE) de 4,1 kg/ha e um erro percentual absoluto médio (MAPE) de 10,1% para o peso total, e 4,6 kg/ha de MAE e 12,4% de MAPE para o peso comercial. O modelo RBF apresentou erros ligeiramente maiores, com 4,9 kg/ha e 11,9% de MAE e MAPE, respectivamente, para o peso total, e 4,7 kg/ha de MAE e 12,8% de MAPE para o peso comercial. Esses valores sugerem que ambos os modelos tiveram dificuldade em prever o peso comercial com precisão, embora o MLP tenha se saído ligeiramente melhor que o RBF.

TABELA 1. Erro dos modelos.

	MAE (ton.ha^{-1})	MAPE (%)	Algoritmos
Total	4.1	10.1	MLP
	4.9	11.9	RBF
Comercial	4.6	12.4	MLP
	4.7	12.8	RBF

A Tabela 2 aponta para uma análise de sensibilidade dos modelos em relação a três índices de vegetação utilizados para predição da produtividade da batata: NDVI, NDRE e GNDVI. O modelo MLP foi mais sensível ao NDRE assim como a rede RBF.O Indice GNDVI não foi utilizado no modelo de predição da rede MLP, enquanto, para a rede RBF este índice aparece com o segundo mais importante no modelo. O NDVI aparece em ambos os modelos, sendo o segundo mais importante para a rede MLP e o terceiro na RBF. Conforme apresentado por Mukiibi et al., (2024) os índices de vegetação aqui abordados estão entre os mais usados para prever o rendimento da batata e são os que geraram modelos com maiores precisões, com destaque para o NDVI, seguido do NDRE e do GNDVI.

TABELA 2. Ánalise de sensibilidade dos modelos

	NDVI	NDRE	GNDVI
MLP	2	1	
RBF	3	1	2

Os resultados demonstram que a utilização de redes neurais artificiais aplicadas às imagens PlanetScope é promissora visando a predição de produtividade da batata, chegando a erros menores que 13%. Trabalhos de predição destinados a cultura da batata ainda são escassos, o que aumenta a relevância do presente estudo. Pereira et al. (2008) propuseram método de predição baseado em variáveis climáticas, observando subestimação de aproximadamente 10%. A principal vantagem do uso do sensoriamento remoto diante de modelos agroclimáticos como o mencionado, é a facilidade de acesso aos dados, não sendo necessário recorrer a estações e sensores, nem sempre presentes na área de interesse.

CONCLUSÃO

O uso de redes neurais artificiais aplicado a imagens de sensoriamento remoto orbital mostrou-se promissor para a predição de produtividade de batata, total e comercial, com destaque para os algoritmos MLP. Para a obtenção de modelos mais acurados e precisos é importante incrementar o conjunto de dados com novas avaliações em trabalhos futuros.

AGRADECIMENTOS

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP - processos n. 2023/14041-2, 2023/08119-9, 2022/16084-8 e 2021/06029-7) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro.

REFERÊNCIAS

Gómez, D., Salvador, P., Sanz, J., & Casanova, J. L. (2019). Potato yield prediction using machine learning techniques and sentinel 2 data. **Remote Sensing**, 11(15), 1745.

Li, B., Xu, X., Zhang, L., Han, J., Bian, C., Li, G., ... & Jin, L. (2020). Above-ground biomass estimation and yield prediction in potato by using UAV-based RGB and hyperspectral imaging. **ISPRS Journal of Photogrammetry and Remote Sensing**, 162, 161-172.

Pereira, A. B., Nova, n. A. V., Ramos, v. J., Pereira, A. R (2008). Potato potential yield based on climatic elements and Cultivar characteristics. **Bragantia**, Campinas, v.67, n.2, p.327-334.

Mukiibi, A., Machakaire, A. T. B., Franke, A. C., Steyn, J. M. (2024) A Systematic Review of Vegetation Indices for Potato Growth Monitoring and Tuber Yield Prediction from Remote Sensing. **Potato Research**, 1-40.

IDENTIFICAÇÃO DE ZONAS DE MANEJO PARA A APLICAÇÃO DE REGULADOR DE CRESCIMENTO NA CULTURA DO ALGODÃO UTILIZANDO BIOMASS PROXY

LAYANE CARMEM ARRUDA DA ROCHA [1]; MAYKON RODRIGO GOMES DE BARROS [3]; MICHEL CASTRO MOREIRA [2]

[1]Doutoranda. Viçosa - MG. Universidade Federal de Viçosa; [2]Docente. Viçosa - MG. Universidade Federal de Viçosa; [3]Doutorando. Gurupi - TO. Universidade Federal do Tocantins

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

O NDVI (Índice de Vegetação por Diferença Normalizada) tem sido amplamente utilizado para definir zonas de aplicação de reguladores de crescimento em lavouras de algodão. No entanto, no estado do Mato Grosso, é comum que, durante o período adequado para essa aplicação, a presença de nuvens interfira na elaboração dos mapas de NDVI. Uma alternativa para superar esse problema é o uso do Biomass Proxy, um novo produto de monitoramento de vegetação que fornece dados sobre a dinâmica da biomassa das culturas acima do solo, com uma resolução espacial de 10 metros. O objetivo deste estudo foi avaliar a eficácia do Biomass Proxy na identificação de zonas de manejo para a aplicação de reguladores de crescimento na cultura do algodão. Para isso, foram obtidas imagens RGB para o cálculo do NDVI e imagens do Biomass Proxy das áreas de estudo. Foram realizadas sete classificações para cada mapa. A partir dessas imagens, geraram-se pontos aleatórios com espaçamento de 15x15 metros, e amostraram-se seus valores para calcular a correlação entre o NDVI e o Biomass Proxy. Os dados foram submetidos ao teste de normalidade de Shapiro-Wilk e, em seguida, ao teste de correlação. Foram aplicadas as métricas estatísticas Percent Bias (PBIAS) e Raiz do Erro Médio Quadrático (RMSE) para compreender a relação entre os dados. Embora o comportamento entre o NDVI e o Biomass Proxy seja correlato, observou-se que a amplitude do NDVI pode ser até duas vezes maior que a do Biomass Proxy. Esse fato foi confirmado pela análise do RMSE, que indicou uma diferença de aproximadamente 48% entre os valores dos dois índices. O PBIAS demonstrou que os dados do Biomass Proxy tendem a ser menores do que os do NDVI. O Biomass Proxy mostrou-se eficiente para a delimitação de zonas de manejo para a aplicação de reguladores de crescimento e revelou-se mais adequado do que o NDVI saturado para essa finalidade.

PALAVRAS-CHAVE: Sensoriamento remoto; Agricultura; NDVI

ABSTRACT

The NDVI (Normalized Difference Vegetation Index) has been widely used to define application zones for growth regulators in cotton crops. However, in the state of Mato Grosso, it is common that, during the appropriate period for this application, the presence of clouds interferes with the preparation of NDVI maps. An alternative to overcome this problem is the use of Biomass Proxy, a new vegetation monitoring product that provides data on the dynamics of above-ground crop biomass, with a spatial resolution of 10 meters. The objective of this study was to evaluate the effectiveness of Biomass Proxy in identifying management zones for the application of growth regulators in cotton crops. For this, RGB images were obtained to calculate the NDVI and Biomass Proxy images of the study areas. Seven classifications were carried out for each map. From these images, random points were generated with a spacing of 15x15 meters, and their values ??were sampled to calculate the correlation between the NDVI and the Biomass Proxy. The data were subjected to the Shapiro-Wilk normality test and then the correlation test. The statistical metrics Percent Bias (PBIAS) and Root Mean Square Error (RMSE) were applied to understand the relationship between the data. Although the behavior between NDVI and Biomass Proxy is correlated, it was observed that the amplitude of NDVI can be up to two times greater than that of Biomass Proxy. This fact was confirmed by the

RMSE analysis, which indicated a difference of approximately 48% between the values ??of the two indices. PBIAS demonstrated that Biomass Proxy data tends to be lower than NDVI data. Biomass Proxy proved to be efficient for delimiting management zones for the application of growth regulators and proved to be more suitable than saturated NDVI for this purpose.

KEYWORDS: Remote Sensing; Agriculture; NDVI

INTRODUÇÃO

A aplicação de regulador de crescimento na cultura do algodão é utilizada como estratégia para maximizar a produção por planta, buscando o equilíbrio entre o crescimento vegetativo e o reprodutivo (COTHREN; OOSTERHUIS, 2010). Embora a prescrição da aplicação do regulador seja feita a partir da medição do algodoeiro, em grandes áreas agrícolas tem-se adotado a aplicação por zonas de manejo. Essas zonas, por sua vez, são elaboradas a partir dos mapas de NDVI (*Normalized Difference Vegetation Index*) das áreas produtivas, sendo então analisada a necessidade de aplicação e a respectiva dosagem de produto. Na geração dos mapas de NDVI tem se utilizado imagens de satélites. Todavia, no período de desenvolvimento da cultura as imagens de satélites apresentam nuvens, dificultando a avaliação espacial da diferença nas lavouras. Uma alternativa para tal problema está no uso do *Biomass Proxy* (VANDERSAT, 2024), que é um novo produto de monitoramento de vegetação que oferece dados para a análise da dinâmica da biomassa das culturas acima do solo com resolução espacial de 10 m. Burger et al. (2024) demonstraram que o *Biomass Proxy* pode ser uma ferramenta valiosa para auxiliar no manejo de culturas, particularmente em regiões nubladas.

OBJETIVOS

Avaliar o uso do *Biomass Proxy* para a identificação de zonas de manejo para a aplicação de regulador de crescimento na cultura do algodão.

MATERIAL E MÉTODOS

O estudo foi realizado para uma lavoura de algodão, plantadas em 28 dezembro de 2023, em áreas de 700 hectares, localizadas no estado do Mato Grosso. Foram adquiridas imagens do projeto Planet, referente a maio de 2024, quando o algodão estava com 120 dias após o plantio. As imagens foram pré-processadas em ambiente de Sistema de Informações Geográficas (SIG), utilizando o software ArcGIS, para o cálculo do NDVI, que é expresso pela Equação 1:

$$NDVI = NIR - RED/NIR + RED \quad \text{Eq. (20)}$$

em que, NDVI - *Normalized Difference Vegetation Index*; NIR - faixa do espectro do infravermelho próximo; e RED - faixa do espectro da banda do vermelho.

Após a obtenção dos mapas de NDVI das áreas de estudo, as imagens foram classificadas, considerando sete classes, levando-se em consideração os valores mínimo e máximo de NDVI da imagem. O *Biomass Proxy* das áreas de estudo foi obtido a partir da nova coleção do projeto Planet, que é uma fusão de imagens ópticas e de micro-ondas de satélite, com resolução de 10 m. Este produto integra dados de microondas dos satélites Sentinel-1 e imagens ópticas do Sentinel-2, ambos da Agência Espacial Europeia (ESA). Os mapas de *Biomass Proxy* das áreas de estudo também foram classificados em seis classes, considerando o valor mínimo e máximo. Assim, a partir das imagens, foram gerados pontos aleatórios, considerando o espaçamento de 15x15 metros e amostrados os seus valores, a fim de calcular a correlação entre o NDVI e o *Proxy de Biomassa*. Os valores foram submetidos ao teste de normalidade de Shapiro-Wilk e em seguida ao teste de correlação. Também foi gerada uma regressão linear, para entender como a variável NDVI pode explicar a variável *Biomass Proxy*. Para comparar os dois índices, foi calculado o *Percent Bias* (PBIAS) (Equação 2), a

fim de medir a tendência média dos valores do NDVI (adotou-se como o observado) a serem maiores ou menores do que os valores observados no *Biomass Proxy* (adotou-se como simulado), e a Raiz do Erro Médio Quadrático (RMSE) (Equação 3). Todas as análises estatísticas foram realizadas no software Rstudio.

$$PBIAS = 100\frac{\sum_{i=1}^{N}(Si-Oi)}{\sum_{i=1}^{N}(Oi)} \quad \text{Eq. (21)}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{N}(Si-Oi)^2}{n}} \quad \text{Eq. (22)}$$

em que, S_i - representa o *Proxy de Biomassa*; e O_i - representa o NDVI.

RESULTADOS E DISCUSSÃO

Na Figura 1 apresentam-se os mapas da classificação do NDVI e do *Biomass Proxy*, assim como as zonas de manejo da área de estudo.

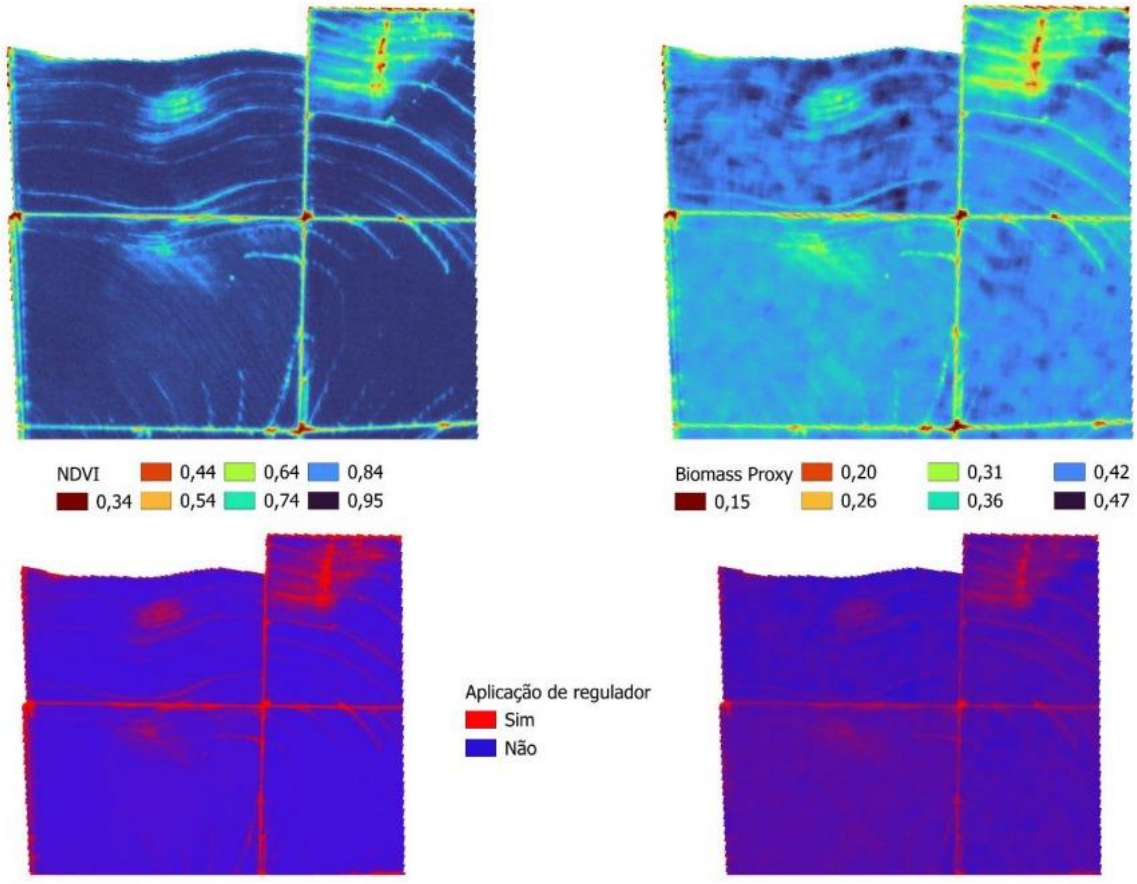


FIGURA 1. Classificação do NDVI e proxy de Biomassa, e suas possíveis zonas de aplicação de regulador de crescimento.

Observa-se na figura acima que as manchas que aparecem no NDVI, são equivalentes ao Biomass Proxy. Como a lavoura estava com cerca de 120 dias, e comum termos um alto vigor vegetativo e consequentemente valores de NDVI elevado. Conforme Fabri et al. (2023) índices de vegetação possibilitaram a discriminação do vigor vegetativo. Analisando as escalas da legenda, nota-se que o

Biomass Proxy apresenta valores cerca de 50% menores que o NDVI. Sendo assim, esses produtos além de suprir a falta de imagens devido a condições atmosféricas, podem vir a atender determinados momentos em que o NDVI esteja saturado. De acordo com Gu et al. (2013), os índices ópticos, e seus subprodutos, como o NDVI, saturam sobre culturas com alta densidade de vegetação. Além de aplicações de regulador de crescimento, Burger et al. (2024) enfatiza que o Biomass Proxy oferece oportunidades que incluem monitoramento aprimorado do crescimento das culturas, detecção de eventos e detecção de estágios fenológicos. Na Figura 2 apresentam-se as métricas estatísticas de comparação entre o NDVI e o *Biomass Proxy* para os 100 pontos obtidos aleatoriamente na área de estudo. É possível observar na Figura 3 o comportamento linear entre a variável dependente (que neste caso adotamos o *Biomass Proxy*) e a variável independente (NDVI). Verifica-se que na regressão linear os valores apresentam um forte relacionamento entre as variáveis, sendo ainda confirmado pelo alto valor do coeficiente de determinacao (R^2 = 0,93). De acordo com o teste de Shapiro-Wilk, os dados não apresentaram distribuição normal (p-valor < 0.05), sendo então determinado o coeficiente de correlação de Spearman (ρ), que conforme a classificação de Cohen (1992), os dados apresentam alta força monotônica entre as variáveis.

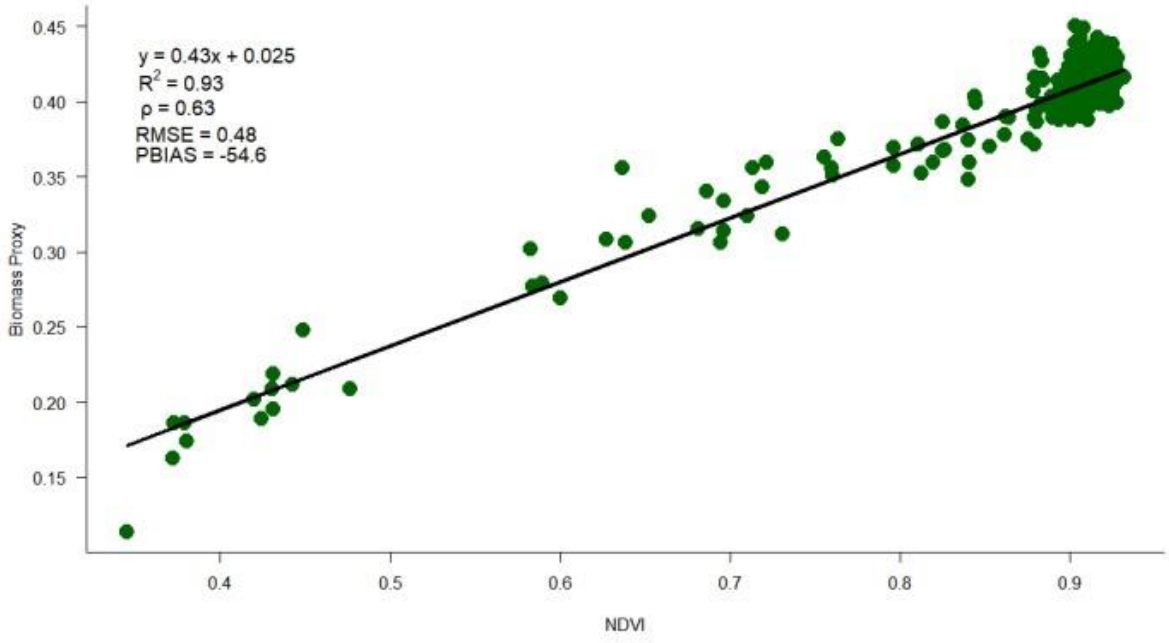


FIGURA 2. Métricas estatisticas de comparação entre o NDVI e o *Biomass Proxy* da área de estudo.

Apesar do comportamento entre o NDVI e o *Biomass Proxy* serem correlatos, verifica-se que a amplitude do NDVI chega a ser duas vezes maior que o do *Biomass Proxy*, fato também confirmado pela análise do RMSE, que indicou uma diferença entre os valores dos dois índices em torno de 48%. O PBIAS, por sua vez, demonstra que os dados do *Biomass Proxy* tendem a ser menores do que os do NDVI. De acordo com Javali et al. (2021), a interpretação dos dados de radar ou imagens de radar de abertura sintética (SAR) é mais desafiadora do que os dados ópticos, que geralmente são obtidos nos comprimentos de onda azul, verde e vermelho (RGB). Sendo assim, o entendimento do comportamento desses dados facilita a sua interpretação. Como o NDVI é bastante consolidado e utilizado na tomada de decisão, uma saída para entendimento dos dados SAR é compará-lo com o NDVI.

CONCLUSÃO

O NDVI e o biomass proxy, apresentaram alta correlação. Sendo que o biomass proxy e mais sensível a análises. Além disso, biomass proxy se mostrou eficiente para delimitação de zonas de manejo para

aplicação de regulador de crescimento, em épocas de nuvens, e ainda, torna-se mais adequado para uso, quando comparado ao NDVI saturado. Todavia, e importante conhecer bem as características desse índice.

AGRADECIMENTOS

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio à pesquisa.

A PlanetScope pelo fornecimento das imagens,

REFERÊNCIAS

BURGER, R.; AOUIZERATS, B.; DEN BESTEN, N.; GUILLEVIC, P.; CATARINO, F.; VAN DER HORST, T.; JACKSON, D.; KOOPMANS, R.; RIDDERIKHOFF, M.; ROBSON, G.; et al. The Biomass Proxy: Unlocking Global Agricultural Monitoring through Fusion of Sentinel-1 and Sentinel-2. **Remote Sens**. 2024, 16, 835. https://doi.org/10.3390/rs16050835

COHEN, J. Statistical power analysis. **Current Directions in Psychological Science**, v. 1, n. 3, p. 98-101, 1992.

COTHREN, J. T.; OOSTERHUIS, D. M. Use of growth regulators in cotton production. In: STEWART, J. McD.; OOSTERHUIS, D. M.; HEITHOLT, J. J.; MAUNEY, J. R. (Ed.). **Physiology of cotton**. Dordrecht: Springer, 2010. p. 289-303.

FABRI, T. M. P.; MELLO, G. M. de; FERRARI, J. L. PELUZIO, J. B. E.; SOUZA, M. N. **B**ehavior of Vegetation Indexes in Coffee Trees through Data Captured by Multispectral Sensor in Remote Pilotted Aircraft. **Revista de Inovação e Ciência**, v. 9, n. 1, p. 01-15, 2023. DOI: 10.36524/ric.v9i1.1850.

GU, Y.; WYLIE, B.K.; HOWARD, D.M.; PHUYAL, K.P.; Ji, L. NDVI saturation adjustment: A new approach for improving cropland performance estimates in the Greater Platte River Basin, USA. **Ecol. Indic**. 2013, *30*, 1-6.

JAVALI, A.; GUPTA, J.; SAHOO, A. **A review on Synthetic Aperture Radar for Earth Remote Sensing: Challenges and Opportunities**. In: PROCEEDINGS OF THE 2021 SECOND INTERNATIONAL CONFERENCE ON ELECTRONICS AND SUSTAINABLE COMMUNICATION SYSTEMS (ICESC), 2021, Coimbatore, India. Anais... Coimbatore: [s.n.], 2021. p. 596-601.

VANDERSAT. Biomass proxy product specification. VanderSat. Disponível em: https://docs.vandersat.com/data_products/biomass_proxy/specification.html. Acesso em: 10 ago. 2024.

DIFERENCIAÇÃO DE CULTIVARES DE BATATA A PARTIR DE TÉCNICAS DE SENSORIAMENTO REMOTO E APRENDIZADO DE MÁQUINAS

Bruno Ripa Baptista [1]; Airton Andrade da Silva [2]; Samira Luns Hatum de Almeida [3]; Vinicius dos Santos Carreira [4]; Rouverson Pereira da Silva [5]

[1]Bolsista. Via de acesso prof. paulo donato castellani. Unesp/Jaboticabal; [2]Bolsista. Via de acesso prof. paulo donato castellani. Unesp/Jaboticabal; [3]Bolsista. Via de acesso prof. paulo donato castellani. Unesp/Jaboticabal; [4]Bolsista. Via de acesso prof. paulo donato castellani. Unesp/Jaboticabal; [5]Docente. Via de acesso prof. paulo donato castellani. Unesp/Jaboticabal

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Objetivou-se realizar a diferenciação de duas cultivares de batata semente em estádios iniciais a partir do uso do Índice de Vegetação por Diferenciação Normalizada (NDVI), obtido via sensor orbital, e o algoritmo Árvores de Decisão. O trabalho foi realizado em Sacramento - MG, com as cultivares Markies e Asterix em faixas em que foi avaliado o comportamento espectral das duas cultivares de batata a partir de 15 datas de avaliação. Foi realizado uma análise de variância em esquema fatorial com os dados e usado o algoritmo de aprendizado de máquinas Árvores de Decisão para realizar a diferenciação das cultivares. Assim, o NDVI foi capaz de acompanhar o comportamento espectral da cultura ao longo do seu desenvolvimento sendo possível também, através da análise de variância observar que houve diferença significativa entre e dentro das DAP de acompanhamento da lavoura e entre as cultivares estudadas. A diferenciação entre as cultivares realizada a partir do algoritmo Arvores de Decisão possibilitou realizar classificações corretas das cultivares nos estágios iniciais da cultura (52, 58, 62 e 64 DAP) demonstrando a diferença do comportamento espectral entre as cultivares. Não foi possível realizar a diferenciação das cultivares aos 79, 82, 86, 88 e 109 DAP devido a menor variação do NDVI dentro da área nessas datas, dificultando que o algoritmo consiga realizar uma adequada diferenciação entre os valores. Portanto, a diferenciação de cultivares de batatas pode ser realizada em estádios iniciais da cultura a partir do NDVI, obtido via sensor orbital, e o algoritmo de aprendizado de máquinas Árvores de Decisão.

PALAVRAS-CHAVE: *Solanum tuberosum L*; Aprendizado de Máquinas; Sensoriamento remoto

ABSTRACT

The aim of this study was to differentiate two potato cultivars in vegetative stages using the Normalized Differentiation Vegetation Index (NDVI), obtained via an orbital sensor, and the Decision Trees algorithm. The study was carried out in Sacramento, MG, with the Markies and Asterix cultivars in a randomized block experimental design, where the spectral behavior of the two potato cultivars was evaluated based on 15 spectral data. An analysis of variance in a factorial scheme was performed with the data and the Decision Trees machine learning algorithm was used to differentiate the cultivars. Thus, the NDVI was able to monitor the spectral behavior of the crop throughout its development, and it was also possible, through the analysis of variance, to observe that there was a significant difference between and within the DAPs of crop monitoring and between the cultivars studied. The differentiation between cultivars performed using the Decision Trees algorithm allowed for correct classifications of cultivars in the early stages of the crop (52, 58, 62, and 64 DAP), demonstrating the difference in spectral behavior between cultivars. It was not possible to differentiate cultivars at 79, 82, 86, 88, and 109 DAP due to the lower variation in NDVI within the area at these dates, making it difficult for the algorithm to adequately differentiate between values. Therefore, differentiation of potato cultivars can be performed in the early stages of the crop based on NDVI, obtained via an orbital sensor, and the Decision Trees machine learning algorithm.

KEYWORDS: *Solanum tuberosum L*; Machine Learning; Remote Sensing

INTRODUÇÃO

A batata possui importância econômica, social e nutricional, devia a receita de 140 bilhões que gerou em 2022, aos empregos e desenvolvimento regional que gera e por fonte de nutrientes e energia (FAO, 2023; Sousa; Silva, 2023). Devido a importância dessa cultura, tecnologias que visem agregar conhecimento dentro do sistema de produção e auxiliar no aumento da produtividade tornam-se de suma importância.

Dentro dos sistemas de produção são utilizadas diferentes cultivares de batata de acordo com as características procuradas pelo produtor, como menor susceptibilidade a pragas e doenças, maior produtividade e qualidade dos tubérculos. Sendo necessário entender as características e padrão de desenvolvimento das diferentes cultivares para auxiliar na adoção de tecnologia e tomada de decisão frente ao manejo. Porém, a identificação de diferentes cultivares no campo só é possível a partir da observação de algumas características vegetativas, como arquitetura da planta e morfologia das folhas, e nos estádios reprodutivos devido a diferença da coloração e morfologia da flor, tornando-se uma ação que demanda tempo e pode ser subjetiva.

Assim, os Índices de Vegetação (IV), obtidos via sensoriamento remoto orbital, podem ser ferramentas para realizar a diferenciação das cultivares de batata em estádios iniciais a partir da estimativa da quantidade de energia eletromagnética refletida pelo dossel, após a interação da mesma com os pigmentos, água e os espaços intercelulares no interior da folha (Oliveira et al., 2020). Além do uso de aprendizado de máquinas que utiliza algoritmos de decisões que permitem que máquinas aprendam a partir de dados e assim realizem classificações corretas de indivíduos dentro de grupos. Com isso, objetivou-se realizar a diferenciação de duas cultivares de batata semente em estádios iniciais a partir do uso do Índice de Vegetação por Diferenciação Normalizada (NDVI), obtido via sensor orbital, e o algoritmo Árvores de Decisão.

OBJETIVOS

Objetivou-se realizar a diferenciação de duas cultivares de batata semente em estádios iniciais a partir do uso do Índice de Vegetação por Diferenciação Normalizada (NDVI), obtido via sensor orbital, e o algoritmo Árvores de Decisão.

MATERIAL E MÉTODOS

O trabalho foi realizado no primeiro semestre de 2024, no município de Sacramento, MG, numa área localizada nas coordenadas geográficas de 19°59'39" latitude Sul e 47°10'52" longitude Oeste, com altitude de 1030 m. As cultivares de batata semente utilizadas foram Markies e Asterix, plantadas na semana do dia 15 de novembro e que possuem ciclo de 90 a 120 dias.

O delineamento experimental foi em faixas, onde os 80 pontos georreferenciados com GPS para cada cultivar foram tomados como blocos. Foi avaliado o comportamento espectral das duas cultivares de batata a partir de 15 dados espectrais de datas distintas obtidas via sensores Planet Scope 2 que disponibiliza produtos com resolução temporal diária, resolução espectral de 8 bandas (Vermelho, Verde, Azul, Amarelo, Azul Costal, Verde Eu, Borda Vermelha, Infravermelho próximo) e resolução espacial de 3 metros. Foi realizado o cálculo do Índice de Vegetação por Diferenciação Normalizada (eq 1), no Software Qgis versão 3.26, a partir dos dados espectrais, sendo os 15 produtos representados pelos Dias Após o Plantio (DAP) que cada data dos produtos representa.

NDVI = (Infravermelho próximo - Vermelho) / (Infravermelho próximo + Vermelho) (eq 1)

Após a obtenção dos valores do NDVI foi realizado uma análise de variância em esquema fatorial para identificar se há diferença significativa dentro da área avaliada nas diferentes datas, entre as datas e entre as cultivares no programa estatístico R (R CORE TEAM, 2023). Também foi usado o algoritmo de aprendizado de máquinas Árvores de Decisão, usando o programa IBM SPSS STATISTICS (IBM CORP, 2022), para realizar a diferenciação das cultivares a partir da classificação correta dos valores do NDVI dentro da sua respectiva cultivar.

RESULTADOS E DISCUSSÃO

O NDVI que é capaz de acompanhar o comportamento espectral da cultura ao longo do seu desenvolvimento (Figura 1 e Figura 2), sendo possível também, através da análise de variância (Tabela 1), observar que houve diferença significativa entre os blocos, entre as DAP de acompanhamento da lavoura e entre as cultivares estudadas.

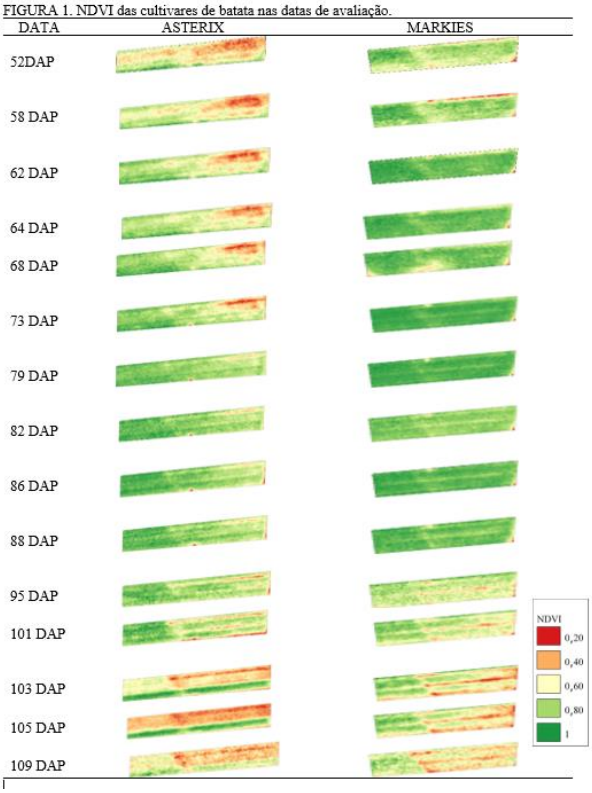


FIGURA 1. NDVI das cultivares de batata nas datas de avaliação.

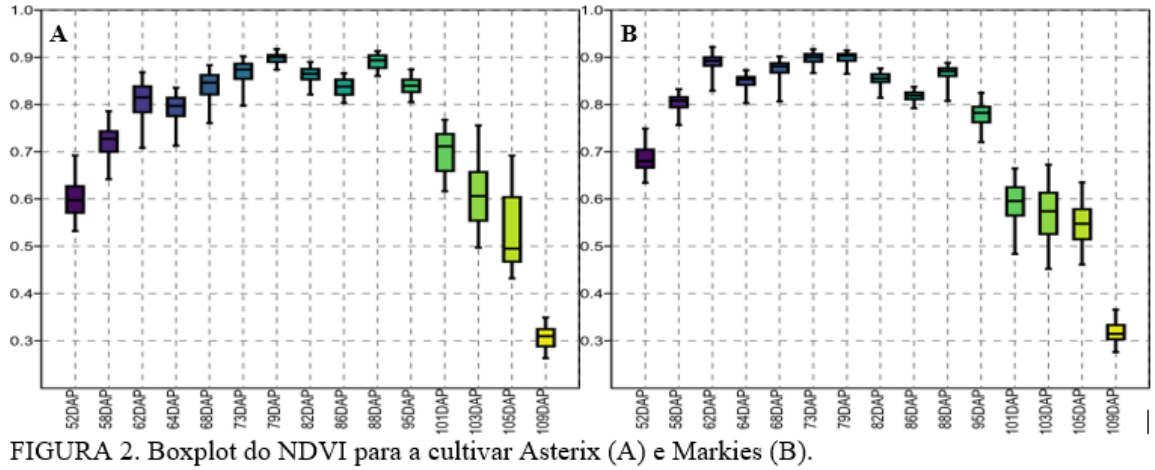


FIGURA 2. Boxplot do NDVI para a cultivar Asterix (A) e Markies (B).

FIGURA 2. Boxplot do NDVI para a cultivar Asterix (A) e Markies (B).

TABELA 1. Análise de variancia em esquema fatorial para as cultivares nas diferentes datas de avaliação.

FV	GL	SQ	QM	Fc	Pr>Fc
DAP	14	61,87	4,41	5395,9	0,0000
CULTIVARES	1	0,04	0,04	58,6	0,0000
DAP x CULTIVARES	14	1,71	0,12	149,4	0,0000
BLOCOS	79	0,72	0,009	11,1	0,0000
Erro	2291	1,87	0,0008		
CV (%)	3,84				

A variação dos valores do NDVI entre as datas de monitoramento foi esperada devido ao comportamento padrão de desenvolvimento da cultura, apresentando baixos valores de refletância nos estádios iniciais, crescimento acentuado até os estádios reprodutivos, com máximo crescimento e desenvolvimentos, e baixos valores nos estádios finais devido a senescência natural da cultura (Souza et al., 2022). Já a diferença estatística entre os blocos mostrou a variabilidade dentro da área, o que traz prejuízos na qualidade dos dados, como observado por Assis et al. (2024), que concluiu que variação na fertilidade do solo influencia nos valores do índice NDVI. A variação dos valores do NDVI entre as cultivares mostra que ambas possuem um comportamento espectral distinto, fato atribuído principalmente a coloração roxa e branca das flores das cultivares Asterix e Markies, respectivamente. Corroborando com Ponzoni, Shimabukuro e Kuplich, (2012), em que plantas com características morfológicas e arquitetura distintas possuem um comportamento espectral distinto, podendo também essa diferença ser relacionada pela variabilidade da área (Figura 1).

A diferenciação entre as cultivares realizada a partir do algoritmo Árvores de Decisão (Figura 3), possibilitou realizar classificações corretas das cultivares nos estágios iniciais da cultura (52, 58, 62 e 64 DAP) demonstrando a diferença do comportamento espectral entre as cultivares. Não foi possível realizar a diferenciação das cultivares aos 79, 82, 86, 88 e 109 DAP devido todos os valores do NDVI terem sidos classificados apenas dentro de uma cultivar, fato observado pela menor variação do índice dentro da área nessas datas, como observado nos Boxplot (Figura 2), dificultando que o algoritmo consiga realizar uma adequada diferenciação entre os valores.

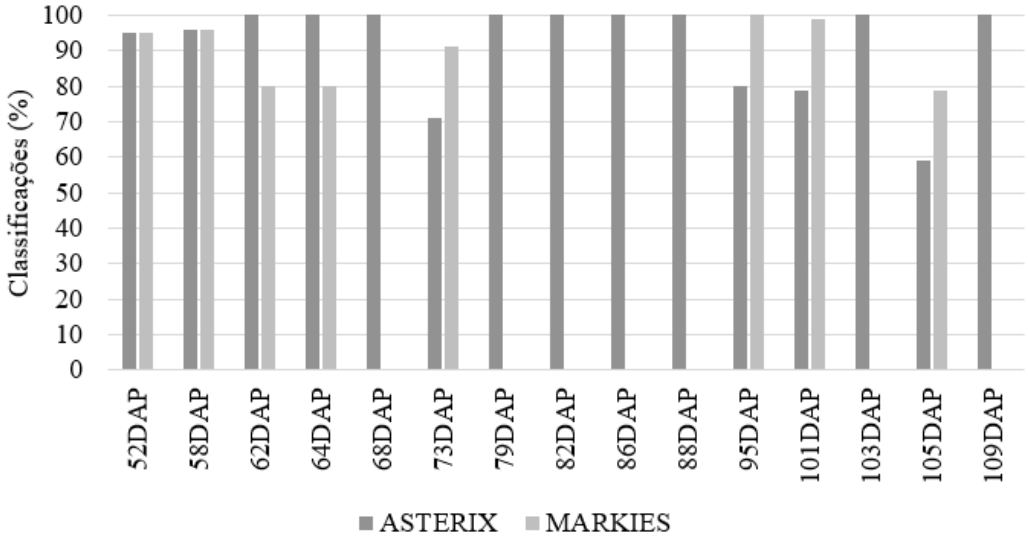


FIGURA 3. Classificações corretas das cultivares a partir das Árvores de decisão.

FIGURA 3. Classificações corretas das cultivares a partir das Árvores de decisão.

A adequada diferenciação das cultivares a partir do comportamento espectral nos estádios vegetativos iniciais possibilita o uso de tecnologias direcionadas para cada cultivar. Pode-se citar como exemplo o desenvolvimento de modelos preditivos de variáveis como a produtividade, capazes de respeitar as particularidades de cada cultivar. Como observado no trabalho de Li et al. (2021), que os índices de vegetação de melhor desempenho e o melhor momento preditivo de rendimento da batata variaram de acordo com as cultivares, devido a diferença entre o comportamento espectral e variabilidade da área.

CONCLUSÃO

A diferenciação de cultivares de batatas pode ser realizada em estádios iniciais da cultura a partir do NDVI, obtido via sensor orbital, e o algoritmo de aprendizado de máquinas Árvores de Decisão.

AGRADECIMENTOS

Agradeço a Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pela concessão da bolsa.

REFERÊNCIAS

QGIS. Geographi Information System QGIS. Disponível em: http://www.qgis.org. Acesso em: 09 maio 2022.

Oliveira M, Queiroz T, Teixeira A, Moreira L, Leão R, Espectrometria de reflectância aplicada à análise das deficiências de nitrogênio e potássio em algodoeiro. **Revista Ciência Agronômica**. v. 51, n. 4, 2020.

SOUZA, Ernando Donato et al. Índice NDVI em trabalho de batata-doce obtido por mapeamento com drone. **Conjecturas**, v. 22, n. 2, pág. 1377-1385, 2022.

ASSIS, Pablo H. de S. et al. Vegetation indices for monitoring agronomic performance of potato under combinations of mineral and organic fertilization1. **Brazilian Journal of Agricultural and Environmental Engineering**, v. 28, n. 12, p. e278100, 2024.

IBM CORP. *IBM SPSS Statistics for Windows, versão 28.0.* Armonk, NY: IBM Corp., 2022.

R CORE TEAM. ***R: A language and environment for statistical computing***. Vienna: R Foundation for Statistical Computing, 2023.

Ponzoni FJ, Shimabukuro, Y. E.; Kuplich, T. M. **Sensoriamento remoto da vegetação**. 2. 23 ed.; Oficina de Textos: São Paulo, Brasil, 2012, 160.

LI, Dan et al. Melhorando a previsão de rendimento de batata combinando informações de cultivares e dados de sensoriamento remoto de UAV usando aprendizado de máquina. **Remote Sensing**, v. 13, n. 16, p. 3322, 2021.

FAO. ***FAO Statistical Yearbook 2023: World Food and Agriculture.*** Rome: Food and Agriculture Organization of the United Nations, 2023.

PREDIÇÃO DO NITROGÊNIO FOLIAR DA CANA-DE-AÇUCAR UTILIZANDO DADOS ESPECTRAIS DE SATÉLITE: APLICAÇÃO DE REGRESSÃO POR EXTREME GRADIENT BOOSTING

ROMÁRIO PORTO DE OLIVEIRA [1]; THIAGO CAIO MOURA OLIVEIRA [1]; CINTIA CARMEN DE FARIA MELO [1]; RENATO DE MELLO PRADO [2]; TATIANA FERNANDA CANATA [2]; CARLOS EDUARDO ANGELI FURLANI [2]

[1]Bolsista. Jaboticabal, SP. Faculdade de Ciências Agrárias e Veterinárias, FCAV; [2]Docente. Jaboticabal, SP. Faculdade de Ciências Agrárias e Veterinárias, FCAV

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Um dos principais fatores que afetam diretamente a produtividade da cana-de-açúcar é o estado nutricional do nitrogênio. Dessa forma, objetivamos com este trabalho analisar por meio de técnicas de aprendizado de máquina a aplicação de dados espectrais obtidos por imagens de satélite na predição do teor de nitrogênio foliar da cana-de-açúcar. Foram realizados 97 pontos de amostragem regularmente distribuídos (grade de 40x40 m). Em cada ponto, cinco plantas foram amostradas durante a fase de maior desenvolvimento vegetativo da cana-de-açúcar. As amostras foram processadas e submetidas a análises químicas para obtenção do teor de nitrogênio foliar. Índices de vegetação foram calculados a partir dos dados espectrais obtidos do satélite PlanetScope. Foi utilizado o algoritmo Extreme Gradient Boosting for Regression para a predição do conteúdo de nitrogênio. O modelo desenvolvido obteve um R^2 de 0,53, MAE de 0,6 e RMSE de 0,7. Os resultados indicam que o modelo pode ser aplicável na predição não destrutiva do conteúdo de nitrogênio foliar da cana-de-açúcar.

PALAVRAS-CHAVE: Sensoriamento remoto; estado nutricional; índice de vegetação

ABSTRACT

One of the main factors directly affecting sugarcane productivity is the nutritional status of nitrogen. The aim of this study was therefore to use machine learning techniques to analyze the application of spectral data obtained from satellite images in predicting the leaf nitrogen content of sugarcane. A total of 97 sampling points were regularly distributed (40x40 m grid). At each point, five plants were sampled during the sugarcane's peak vegetative stage. The samples were processed and subjected to chemical analysis to obtain the leaf nitrogen content. Vegetation indices were calculated from spectral data obtained from the PlanetScope satellite. The Extreme Gradient Boosting for Regression algorithm was used to predict nitrogen content. The model developed obtained an R^2 of 0.53, MAE of 0.6 and RMSE of 0.7. The results indicate that the model can be applied to the non-destructive and rapid prediction of sugarcane leaf nitrogen content.

KEYWORDS: Remote sensing; nutritional status; vegetation index

INTRODUÇÃO

A cana-de-açúcar é uma cultura de grande importância econômica, sendo o Brasil um dos maiores produtores do mundo. Um dos principais fatores que afetam diretamente a produtividade da cana-de-açúcar é o estado nutricional do nitrogênio. O nitrogênio é fundamental para o processo de fotossíntese, atua no crescimento da planta, no perfilhamento e no teor de sacarose. A deficiência do nitrogênio afeta diretamente a produtividade da cultura da cana-de-açúcar. Por outro lado, o uso excessivo, além de elevar os custos de produção, podem prejudicar o meio ambiente. Dessa forma, o

monitoramento otimizado do estado nutricional é essencial para o desenvolvimento de uma agricultura sustentável.

Para quantificar o nitrogênio por meio dos métodos tradicionais, é necessário a realização de amostragem foliar em campo e análises químicas laboratoriais, que são caras, demoradas, além de gerarem resíduos químicos ao meio ambiente. Na literatura, encontra-se como umas das principais soluções para o monitoramento das culturas, a utilização do sensoriamento remoto (SR). O SR é uma tecnologia não destrutiva, que apresenta uma abordagem econômica na obtenção dos dados. Algumas abordagens são descritas na literatura utilizando técnicas de SR para predição do nitrogênio (Soltanikazemi et al., 2022; Peng et al., 2022; Qiu et al., 2021). No entanto, o nitrogênio foliar ainda é quantificado em larga escala utilizando os métodos tradicionais, tornando se inviável uma avaliação detalhada em extensas áreas, devido aos custos elevados e processo trabalhoso. Por tanto, uma abordagem alternativa é necessária.

A utilização de dados de sensoriamento remoto, combinados com técnicas de aprendizado de máquina, permitirá a predição precisa do teor de nitrogênio foliar em cana-de-açúcar, viabilizando a avaliação de grandes áreas agrícolas de forma eficiente e sustentável.

OBJETIVOS

Dessa forma, objetivamos com este trabalho analisar por meio de técnicas de aprendizado de máquina a aplicação de dados espectrais obtidos por imagens de satélite na predição do teor de nitrogênio foliar da cana-de-açúcar.

MATERIAL E MÉTODOS

O trabalho foi desenvolvido em campo comercial de cana-de-açúcar localizado no município de Jaboticabal, São Paulo Brasil. Foi avaliado a variedade CTC 20, 8º Corte, na safra de 2023 em uma área de 20,39 ha. Foram realizados 97 pontos de amostragem regularmente distribuídos (grade de 40x40 m). Em cada ponto, cinco plantas foram amostradas (amostra composta) durante a fase de maior desenvolvimento vegetativo da cana-de-açúcar (8 meses após a colheita), retirando os 20 cm centrais da folha +1 (folha mais alta com colarinho visível-"TVD"), excluída a nervura central, conforme o Boletim 100 do Instituto Agronômico (Raij et al., 1996). Para obtenção do teor de nitrogênio foliar, as amostras foram processadas e submetidas a análises químicas, de acordo Balieiro e Alves (2017). As estatísticas sobre as medições de nitrogênio são exibidas na Tabela 1. Os dados espectrais foram obtidos do satélite PlanetScope. Foram calculados quatro índice de vegetação: índice de vegetação por diferença normalizada (NDVI = NIR - Red / NIR + Red), índice de vegetação verde-vermelho (GRVI = Green - Red / Green + Red), índice de pigmento de estrutura intensiva (SIPI = NIR - Blue / NIR + Blue) e o índice de vegetação amarela por diferença normalizada (YNDVI = NIR - Yellow / NIR + Yellow). Usamos o algoritmo de aprendizado de máquina Extreme Gradient Boosting for Regression (XGBR). XGBR é um algoritmo de aprendizado supervisionado baseado em árvores de decisão. Esse algoritmo constrói um conjunto de árvores de forma iterativa, adicionando novas árvores que melhoram o desempenho do modelo. A cada iteração, ele ajusta uma nova árvore para corrigir os erros (resíduos) das árvores anteriores. Esse processo continua até que os resíduos sejam minimizados ao máximo possível. As novas árvores são criadas usando os gradientes das funções de avaliação para escolher a sequência ideal de divisões (perguntas) nas árvores (Huber et al., 2022). O modelo foi processado ??usando a biblioteca de aprendizado de máquina de código aberto 'scikit-learn' na linguagem de programação Python implementado no VSCode. O conjunto de dados foi dividido em treinamento (80%) e teste (20%). A importância das características foi avaliada por meio da técnica de permutação, com o objetivo de identificar as variáveis que têm maior influência no desempenho do modelo. O desempenho do modelo foi avaliado considerando o

coeficiente de determinação (R^2), erro absoluto médio (MAE), erro quadrático médio (RMSE) e o erro percentual absoluto médio (MAPE).

TABELA 1. Estatísticas do teor de nitrogênio foliar medido pelo método tradicional.

Parâmetro	Mínimo	Máximo	Média	Dp	Variância
Nitrogênio (g/kg)	10.79	17.90	14.73	1.50	2.25

RESULTADOS E DISCUSSÃO

O modelo desenvolvido para predição do nitrogênio foliar da cana-de-açúcar obteve um coeficiente de determinação (R^2) de 0,53, indicando que ele explica 53% da variabilidade dos dados (TABELA 2). Estudo realizado por Soltanikazemi et al. (2022) para predição do teor de nitrogênio foliar da cana-de-açúcar, utilizando dados espectrais do Sentinel-2 e o algoritmo de floresta aleatória, apresentou um resultado ligeiramente mais preciso ($R^2 = 0,59$). No entanto, considerando que o presente trabalho foi desenvolvido com um maior número de amostras, a explicação da variabilidade do modelo pode ser considerada aceitável, devido à maior diversidade dos dados.

TABELA 2. Desempenho do modelo XGBR na predição do nitrogênio (N) foliar.

Modelo	Nutriente	IVs	R^2	MAE (g/kg)	RMSE (g/kg)
XGBR	N	NDVI GRVI SIPI YNDVI	0,53	0,6	0,7

Considerando que a técnica de SR é uma alternativa de menor custo em comparação aos métodos tradicionais, uma explicação de 53% da variabilidade ($R^2 = 0,53$) pode ser de grande valor e aceitável no contexto de SR. O modelo obteve métricas de desempenho satisfatórias, com erros relativamente baixos (MAE = 0,6 e RMSE = 0,7). Esse nível de ajuste pode ser considerado de extrema utilidade na orientação de decisões agronômicas, como na avaliação para a aplicação de fertilizantes e manejo da cultura. Conforme ilustrado na Figura 1, os índices GRVI e NDVI demonstraram ser, respectivamente, os mais influentes na predição do nitrogênio. Esses resultados indicam que a reflectância nas faixas vermelha, verde e NIR desempenha um papel crucial na estimativa dos níveis de nitrogênio.

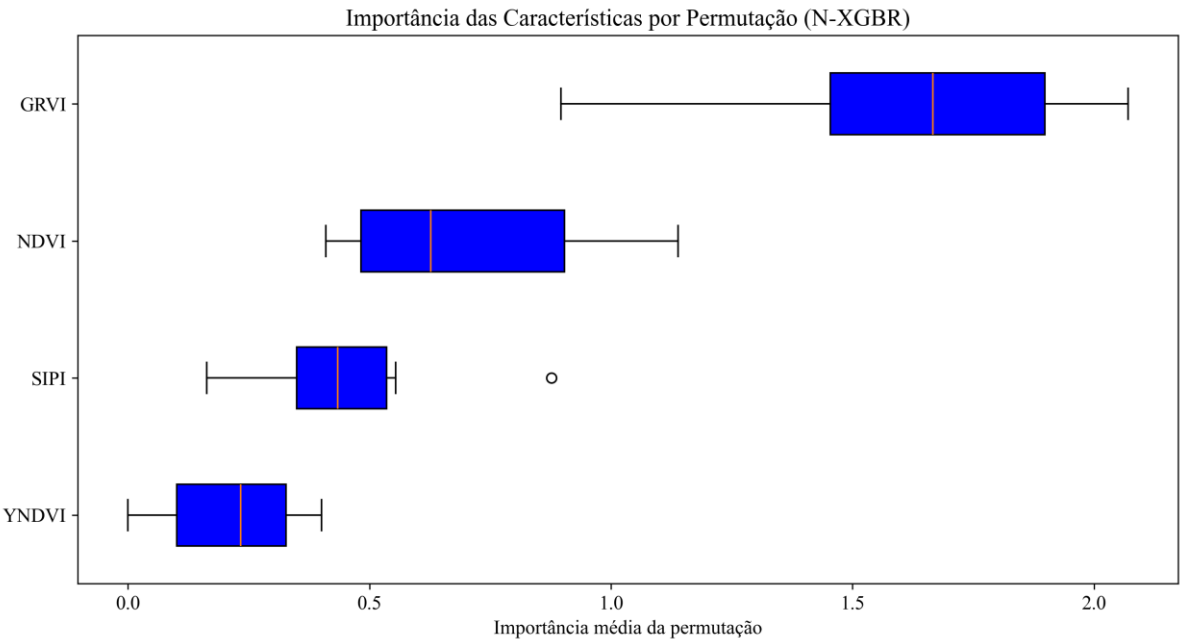


FIGURA 1. Importância das variáveis para predição de nitrogênio.

Nas Figuras 2 e 3, apresentam-se os mapas de nitrogênio observado e predito. Observa-se em ambos os mapas padrões que exibem alta similaridade, o que indica que o modelo é eficaz na representação dos níveis de nitrogênio na cultura. Essa correspondência indica que a abordagem utilizada pode ser aplicada na definição de zonas de manejo específico, um dos princípios da agricultura de precisão (Castrignanò et al., 2018). Dessa forma, a capacidade do modelo de identificar áreas com diferentes necessidades nutricionais pode contribuir significativamente para a otimização das práticas agronômicas.

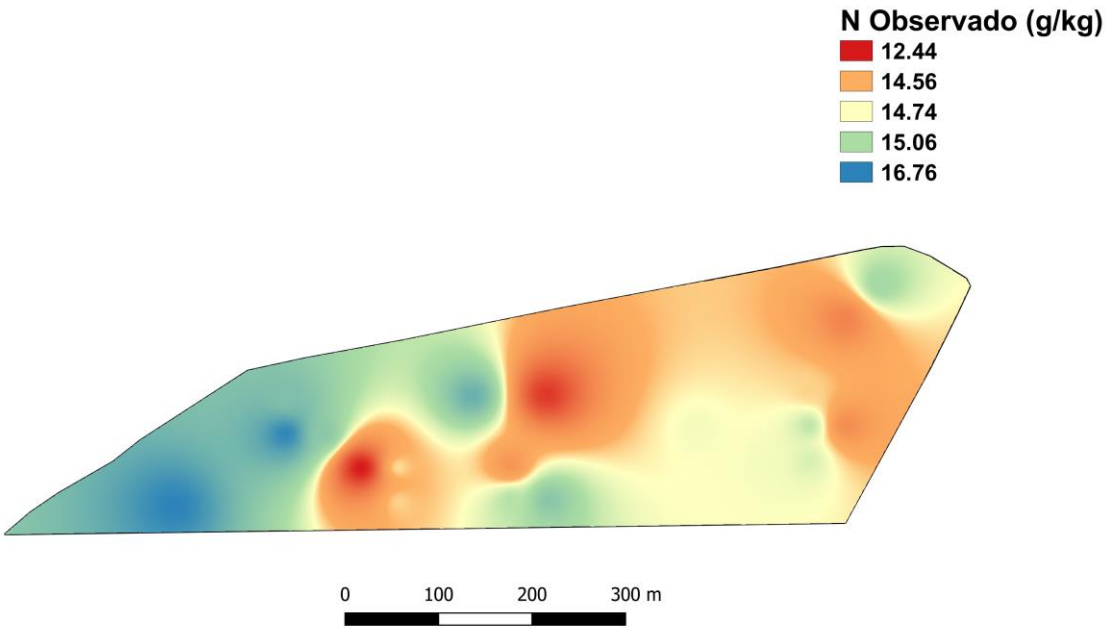


FIGURA 2. Mapa de interpolação do Nitrogênio Observado (IDW).

Embora o modelo tenha apresentado um ajuste e desempenho razoáveis, a utilização do SR aliada às técnicas de aprendizado de máquina oferece uma alternativa de baixo custo, que, no contexto da agricultura de precisão, pode ser extremamente valiosa em termos de economia de recursos e tempo. Além de reduzir a dependência de análises químicas, essa abordagem contribui para a redução de resíduos ambientais, promovendo uma agricultura mais sustentável.

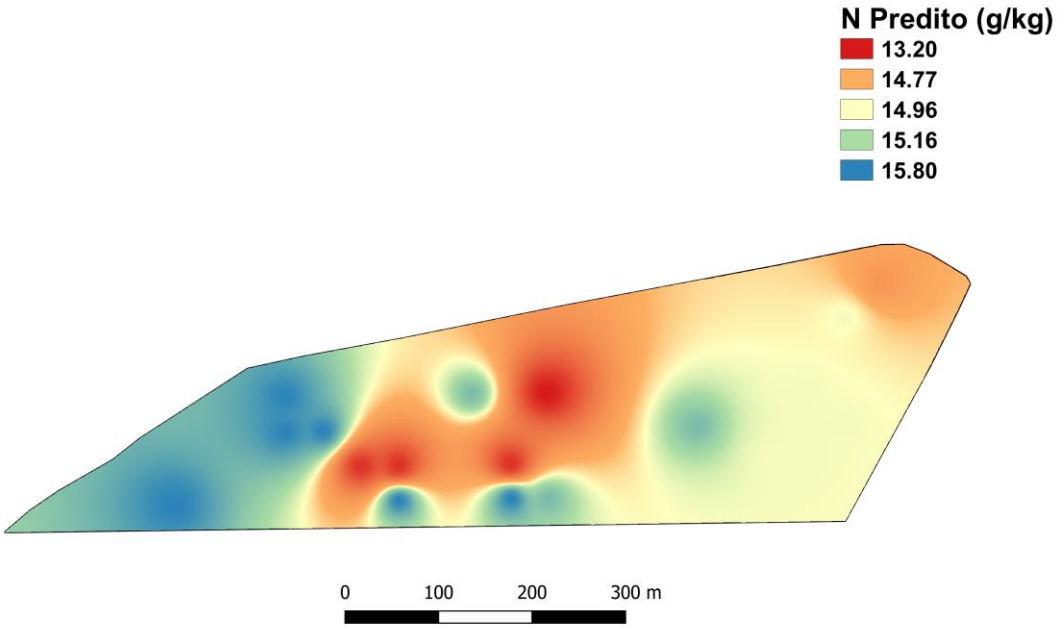


FIGURA 3. Mapa de interpolação do Nitrogênio Predito (IDW).

CONCLUSÃO

O modelo desenvolvido indica que a utilização do sensoriamento remoto com técnicas de aprendizado de máquina é uma valiosa ferramenta para avaliação do estado nutricional de nitrogênio da canade-açúcar. Os resultados revelam que o modelo pode ser utilizado para complementar os métodos tradicionais de análises químicas laboratoriais, sendo aplicável na predição não destrutiva do conteúdo de nitrogênio foliar da cana-de-açúcar.

AGRADECIMENTOS

Este trabalho foi apoiado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES). Gostaríamos de agradecer ao Laboratório de Máquinas e Mecanização Agrícola (LAMMA) pelo suporte e infraestrutura e ao Laboratório de Nutrição de Plantas pelo suporte as análises laboratoriais.

REFERÊNCIAS

BALIEIRO, F. D. C., & ALVES, B. J. R. Nitrogênio total: Kjeldahl. 2017.

CASTRIGNANÒ, A., BUTTAFUOCO, G., QUARTO, R., PARISI, D., ROSSEL, R. V., TERRIBILE, F., ... & VENEZIA, A. A geostatistical sensor data fusion approach for delineating homogeneous management zones in Precision Agriculture. **Catena**, v. 167, p. 293-304, 2018.

RAIJ, B. VAN; CANTARELLA, H. & QUAGGIO, J.A. ESTIMULANTES. IN: RAIJ, B. VAN; CANTARELLA, H; QUAGGIO, J. A. & FURLANI, A. M. C., eds. Recomendaç?es de adubaç?o e calagem para o Estado de S?o Paulo. 2.ed. Campinas, Instituto Agronômico & Fundaç?o IAC, 1996a. 285p. (Boletim Técnico, 100).

HUBER, F., YUSHCHENKO, A., STRATMANN, B., & STEINHAGE, V. Extreme Gradient Boosting for yield estimation compared with Deep Learning approaches. **Computers and Electronics in Agriculture**, v. 202, p. 107346, 2022.

SOLTANIKAZEMI, M., MINAEI, S., SHAFIZADEH-MOGHADAM, H., & MAHDAVIAN, A. Field-scale estimation of sugarcane leaf nitrogen content using vegetation indices and spectral bands of Sentinel-2: Application of random forest and support vector regression. **Computers and Electronics in Agriculture**, v. 200, p. 107130, 2022.

PENG, X., CHEN, D., ZHOU, Z., ZHANG, Z., XU, C., ZHA, Q., ... & HU, X. Prediction of the nitrogen, phosphorus and potassium contents in grape leaves at different growth stages based on UAV multispectral remote sensing. **Remote Sensing**, v. 14, n. 11, p. 2659, 2022.

QIU, Z., MA, F., LI, Z., XU, X., GE, H., & DU, C. Estimation of nitrogen nutrition index in rice from UAV RGB images coupled with machine learning algorithms. **Computers and Electronics in Agriculture**, v. 189, p. 106421, 2021.

6. Técnicas de análise de dados

DETECÇÃO DE PRAGAS DA AVICULTURA USANDO REDES NEURAIS CONVOLUCIONAIS

Geordano Dalmédico [1]
[1]Analista. Concórdia, SC. Embrapa Suínos e Aves

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
O trabalho apresenta a implementação de uma Rede Neural Convolucional (CNN), por meio do uso da arquitetura *Single Shot Multibox Detector* (SSD) para detecção de pragas que representam riscos à biosseguridade de granjas avícolas, como pombos. O algoritmo foi construído por meio da linguagem Python, utilizando o modelo pré-treinado SSD Mobilenet v1 Caffe. O modelo foi capaz de identificar corretamente a presença de aves em 80,4% das ocorrências.

PALAVRAS-CHAVE: Redes neurais convolucionais; Inteligência artificial; Biosseguridade

ABSTRACT
This paper describes the implementation of a Convolutional Neural Network (CNN) by using the Single Shot Multibox Detector (SSD) architecture to detect threats that represent risks to the biosecurity of poultry farms, such as pigeons. We applied the Python language to build the algorithm through the SSD Mobilenet v1 Caffe pre-trained model. The model developed in this study was able to identify the presence of birds in 80.4% of occurrences analysed.

KEYWORDS: Convolutional neural networks; Artificial intelligence; Biosecurity

INTRODUÇÃO

O Brasil é o segundo maior produtor (14 milhões de ton. em 2023) e o maior exportador (5,1 milhões de ton. em 2023) de carne de frango do mundo (Embrapa Suínos e Aves, 2024). Este sucesso deve-se, entre outros fatores, às medidas de biosseguridade adotadas na produção, que evitam a entrada e a propagação de doenças, garantindo a segurança dos alimentos e a saúde dos animais (Embrapa, 2023).

Algumas das principais ameaças à saúde dos plantéis avícolas do país possuem pombos (*Columba livia*) entre seus vetores. Eles são um dos responsáveis pela disseminação, por exemplo, de *Salmonella* spp., cuja ocorrência gera transtornos para a agroindústria e pode acarretar problemas de saúde pública, a depender da gravidade dos surtos. A implementação de medidas eficazes de controle desses animais poderia reduzir a ocorrência de *Salmonella* spp. (Rocha-e-Silva *et al.*, 2014). A doença de *Newcastle* também pode ser transmitida para as aves de criação por meio das fezes de pombos, que contaminam a água e a ração. Sua presença é comum em locais de armazenamento de grãos, aviários, granjas e fábricas de ração (Moraes, 2024).

Redes neurais convolucionais (CNNs) são inspiradas no córtex visual do cérebro humano. Suas camadas convolucionais que extraem as características das imagens, associadas às camadas de *pooling*, que reduzem o número de parâmetros e o uso de memória, tornam essa arquitetura apropriada para o uso com imagens. Uma das principais aplicações das CNNs é a Detecção de Objetos, cujo objetivo é localizar e classificar os objetos contidos em uma imagem (Géron, 2021).

OBJETIVOS

Este trabalho teve como objetivo a utilização de redes neurais convolucionais (CNNs), por meio da arquitetura *Single Shot Multibox Detector* (SSD), para detecção da presença de aves em imagens, visando sua aplicação em sistemas de video monitoramento de granjas avícolas e fábricas de ração, gerando informações que permitam a tomada de medidas, manuais ou automatizadas, para afugentá-las, reforçando a biosseguridade

MATERIAL E MÉTODOS

A arquitetura SSD (*Single Shot Multibox Detector*), proposta por Liu *et al*. (2016), foi projetada para detecção de objetos em tempo real. Ela possibilita a utilização de imagens de resolução mais baixa, tornando-se mais rápida, com precisão equivalente ou até maior do que outras arquiteturas, como a Faster R-CNN e YOLO (Hui, 2018). Além disso, a arquitetura SSD necessita de apenas uma passagem pela imagem, ao contrário das demais. A arquitetura SSD consiste de um componente básico, pré-treinado, seguido de várias camadas convolucionais (Singhal, 2020).

Sendo assim, inicialmente buscou-se um modelo pré-treinado de SSD capaz de identificar pássaros entre as classes de objetos treinadas. O modelo selecionado foi o *SSD Mobilenet v1 Caffe* (Neural Compute Application Zoo, 2023), que foi pré-treinado com o *dataset Pascal Visual Object Classes* (The PASCAL Visual Object Classes Homepage, 2023), da Universidade de Oxford, composto de 11.530 imagens, divididas em 20 classes de objetos: *aeroplane, bicycle, bird, boat, bottle, bus, car, cat, chair, cow, diningtable, dog, horse, motorbike, person, pottedplant, sheep, sofá, train, tvmonitor*.

A aquisição das imagens para os testes foi realizada por meio de uma câmera tipo webcam, marca Logitech, modelo C920. A câmera possui um sensor de imagem do tipo BSI CMOS.

O algoritmo foi elaborado na linguagem Python 3.11.4, por meio da utilização da IDE PyCharm na versão 2023.1.3 (*Community Edition*). Utilizou-se a biblioteca OpenCV (OpenCV, 2023) para capturar as imagens.

A rede SSD foi testada a fim de verificar sua capacidade de identificar a presença de aves nas imagens capturadas. Buscou-se verificar também a ocorrência de falsos negativos, ou seja, a incapacidade de detecção de aves em imagens que as continham e de falsos positivos, ou seja, a detecção de aves em imagens que não as continham. Para isso, o algoritmo foi executado durante 2 dias, entre 8 e 17 horas, com o dispositivo de captura apontando para uma área onde foi depositada ração para aves. Uma função para detecção de movimentos foi criada de modo que, sempre que um movimento fosse detectado, a imagem era salva e analisada em busca de aves. Caso fossem encontradas, uma nova imagem contendo a localização do animal era criada. Por fim, as imagens gravadas foram analisadas para verificar a capacidade de detecção do modelo.

RESULTADOS E DISCUSSÃO

O modelo foi capaz de identificar a presença de aves em tempo real. Foram observadas três espécies diferentes de aves, incluindo pombos.

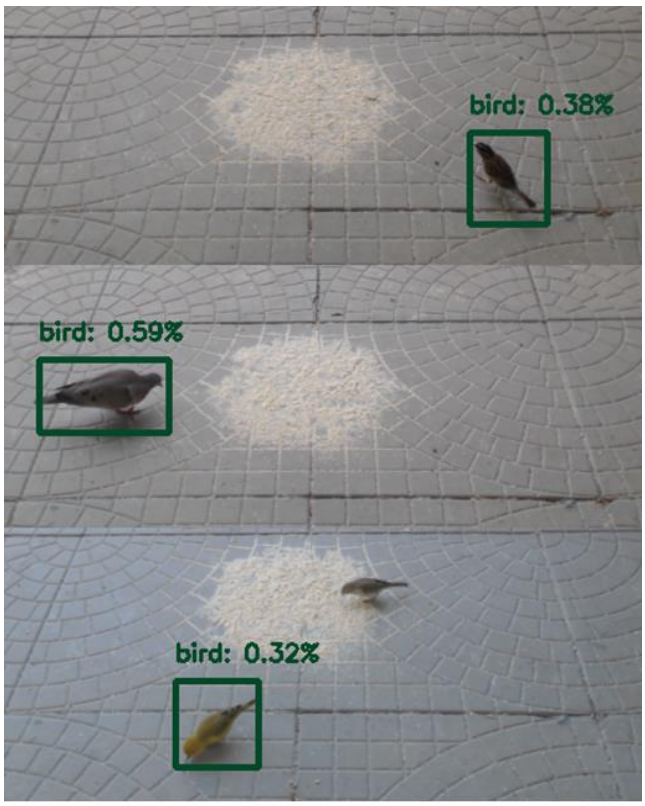


FIGURA 1. Diferentes espécies de aves detectadas.

Ocorreram detecções da presença das aves em diferentes condições de luminosidade, tanto em condições de sombreamento (figura 1), quanto com incidência de sol direto (figura 2). Além disso, as aves foram detectadas em posição de repouso e em voo.



FIGURA 2. Detecção com incidência direta de sol sobre a ave e diferentes posições.

Durante o período de testes, foram registradas 51 ocorrências de aves, das quais 41 foram detectadas pelo modelo, representando 80,4% de acurácia. As demais 19,6% das ocorrências não detectadas correspondem, portanto, a falsos negativos.

Uma limitação importante foi observada na utilização do modelo. Quando a imagem total da câmera (480 x 640px) foi redimensionada e inserida na rede neural, a mesma não foi capaz de detectar as aves presentes. Elas só foram detectadas quando o recorte de 300 x 300px, onde as aves se localizavam, foi usado como entrada. Nesse caso, as aves ocupavam proporcionalmente um percentual maior da área da imagem. Isso denota que o modelo não é capaz de detectar aves menores ou mais distantes.



FIGURA 3. Incapacidade de detecção de aves menores ou mais distantes.

Uma única ocorrência de falso positivo foi detectada (Fig. 4) frente a 41 detecções corretas, correspondendo a apenas 2,4% das detecções.



FIGURA 4. Detecção de falso positivo

CONCLUSÃO

O uso da arquitetura SSD (*Single Shot Multibox Detector*) mostrou-se promissor para auxiliar na solução do problema apresentado. No entanto, é necessário validar o modelo em ambiente real de uso, ou seja, com imagens obtidas através de câmeras instaladas em granjas de aves e fábricas de ração. A obtenção de imagens em maior resolução, possivelmente, irá requerer ajustes no algoritmo.

Melhores resultados podem ser buscados por meio do treinamento de um novo modelo, usando a arquitetura SSD, com a utilização de imagens de outros *datasets* com maior número de imagens, como Coco (330k) (Common Objects In Context, 2023), ImageNet (14M) (Imagenet, 2023) ou Open Images V7 (15M) (Open Images Dataset V7 and Extensions, 2023). Este último é especialmente interessante, pois contém imagens da classe "mouse" e a detecção de roedores tornaria a solução ainda

mais efetiva, uma vez que esse tipo de animal também constitui uma ameaça à biosseguridade de aves.

Além disso, outras arquiteturas podem ser testadas em busca de melhores resultados, como Yolo e Faster R-CNN.

Finalmente, uma vez ajustado, o modelo pode ser utilizado para gerar informações sobre horários e locais com maior presença de aves a fim de subsidiar ações para afugentá-las de forma manual ou automatizada.

REFERÊNCIAS

COMMON OBJECTS IN CONTEXT. **Coco Dataset**. Disponível em: https://cocodataset.org/. Acesso em: 14 out. 2023.

EMBRAPA SUÍNOS E AVES. **Central de Inteligência de Aves e Suínos**: CIAS. Concórdia, 2024. Disponível em: https://www.embrapa.br/suinos-e-aves/cias/estatisticas. Acesso em: 25 jul. 2024.

Embrapa. **Qualidade da carne do campo à mesa**. Disponível em https://www.embrapa.br/qualidade-da-carne/carne-de-aves/producao-de-aves/biosseguridade. Acesso em: 14 out. 2023.

GÉRON, A. **Mãos à obra**: aprendizado de máquina com Scikit-Learn, Keras & TensorFlow. 2. ed. Rio de Janeiro: Editora Alta Books, 2021.

HUI, J. **SSD object detection**: single shot multibox detector for real-time processing. 2018. Disponível em: https://jonathan-hui.medium.com/ssd-object-detection-single-shot-multibox-detector-for-real-time-processing-9bd8deac0e06. Acesso em: 14 out. 2023.

IMAGENET. Disponível em: https://www.image-net.org/. Acesso em: 14 out. 2023.

LIU, W.; ANGUELOV, D.; ERHAN, D.; SZEGEDY, C.; REED, S.; FU, C.-Y.; BERG, A. C. SSD: single shot multibox detector. In: COMPUTER VISION - ECCV, EUROPEAN CONFERENCE, 14., 2016, Amsterdam. **Proceedings...** 2016. Disponível em: https://arxiv.org/pdf/1512.02325.pdf. Acesso em: 14 out. 2023.

MORAES, F. **Doença de Newcastle**: influência dos roedores e pombos na propagação. 2024. Disponível em: https://www.bioseta.com.br/doenca-de-newcastle-influencia-dos-roedores-e-pombos-na-propagacao/. Acesso em: 07 ago. 2024

NEURAL Compute Application Zoo (ncappzoo). **SSD Mobilenet V1 Caffe**. Disponível em: https://movidius.github.io/ncappzoo/networks/ssd_mobilenet_v1_caffe.html. Acesso em: 12 set. 2023.

OpenCV. Disponível em: https://opencv.org/. Acesso em: 14 out. 2023.

OPEN Images Dataset V7 and Extensions. Disponível em: https://storage.googleapis.com/openimages/web/index.html. Acesso em: 14 out. 2023.

ROHA-E-SILVA, R. C.; MACIEL, W. C.; TEIXEIRA, R. S. C.; SALLES, R. P. R. O pombo (Columba livia) como agente carreador de Salmonella spp. e as implicações em saúde pública. **Arquivos do Instituto Biológico**, v. 81, n. 2, p. 189-194, 2014. Disponível em: https://www.scielo.br/j/aib/a/k7dfkkD7WR74pgX6BzkRcWw. Acesso em: 07 ago. 2024

SINGHAL, M. Object detection using SSD mobilenet and tensorflow object detection API : can detect any single class from coco dataset. 2020. Disponível em: https://medium.com/@techmayank2000/object-detection-using-ssd-mobilenetv2-using-tensorflow-api-can-detect-any-single-class-from-31a31bbd0691. Acesso em: 14 out. 2023.

THE PASCAL visual object classes homepage. Disponível em: http://host.robots.ox.ac.uk/pascal/VOC/. Acesso em: 14 out. 2023.

ANÁLISE DA VARIABILIDADE NA SEMEADURA E SEUS EFEITOS NA PRODUTIVIDADE DE MILHO NO SUL DE MINAS

WENDER HENRIQUE BATISTA DA SILVA [1]; ALEXANDRE DOS SANTOS [2]; FRANKLIN DANIEL INÁCIO [1]; ADÃO FELIPE DOS SANTOS [2]; EDUARDO HENRIQUE ARANTES TERRA [1]

[1]Bolsista . Trevo Rotatório Professor Edmir Sá Santos Universidade Federal de, Lavras - MG, 37203-202. Universidade Federal de Lavras; [2]Docente. Trevo Rotatório Professor Edmir Sá Santos Universidade Federal de, Lavras - MG, 37203-202. Universidade Federal de Lavras

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A operação de semeadura é uma das etapas mais importante na implementação de uma lavoura podendo afetar diretamente na produtividade final, um dos fatores que podem influenciar é a densidade de plantas, que é o número de sementes utilizadas em um hectare, onde para cultura existe uma taxa ideal para atingir o máximo rendimento de uma lavoura. Este trabalho tem como objetivo utilizar de mapas de semeadura e colheita para investigar a variabilidade na produção de milho, em uma lavoura localizada na Fazenda Mato Verde, no município de Luminárias - MG, relacionando a densidade de plantas afim de conhecer a quantidade ideal de sementes por hectares na semeadura do milho para atingir maiores produtividades, utilizando de mapas gerados pelas máquinas. Para realização do tratamento desses dados foi utilizado softwares de Sistema de informação Geográficos (SIG) como o Qgis e de plugins instalados no mesmo como SmartMap e o software AutoCad Civil 3D pela ferramenta AgroCad, além de softwares para filtragem de dados como o Map Filter, após os dados filtrados e tratados foram gerados através de interpolações mapas de variabilidade da semeadura ocorreu no dia 06 de outubro de 2022, e da colheita que finalizou no dia 28/02/2023, sendo que para medir a produtividade, foram utilizados dos mapas de colheitas, nos quais foram necessários realizar filtragem dos dados, e correção da umidade de colheita. Dessa forma, podemos verificar a variabilidade espacial utilizada na semeadura.

PALAVRAS-CHAVE: Densidade de plantas; Semeadura; Produtividade agrícola

ABSTRACT

: The sowing operation is one of the most important steps in the implementation of a crop and can directly affect the final productivity. One of the factors that can influence it is the plant density, which is the number of seeds used in a hectare, where there is an ideal rate for the crop to achieve maximum yield. This work aims to use sowing and harvesting maps to investigate the variability in corn production in a crop located at Fazenda Mato Verde, in the municipality of Luminárias - MG, relating the plant density in order to know the ideal amount of seeds per hectare in corn sowing to achieve higher productivity, using maps generated by the machines. To process these data, Geographic Information System (GIS) software such as Qgis and plugins installed in it, such as SmartMap and AutoCad Civil 3D software through the AgroCad tool, were used, in addition to data filtering software such as Map Filter. After the filtered and processed data, variability maps were generated through interpolations of the sowing that occurred on October 6, 2022, and of the harvest that ended on February 28, 2023. To measure productivity, harvest maps were used, in which it was necessary to filter the data and correct the harvest moisture. In this way, we can verify the spatial variability used in sowing.

KEYWORDS: Plant density; Seeding; Agricultural productivity

INTRODUÇÃO

O cultivo de milho no Brasil pode ocorrer em diferentes períodos, sendo principalmente produzido na safra verão e o milho de segunda safra, também conhecido como safrinha, os quais podem fazer com que ocorram condições pouco favoráveis ao desenvolvimento pleno da cultura (SILVA, 2020).

O Brasil é um país que tem destaque no cenário internacional ocupando a terceira posição entre os maiores produtores, atrás apenas de Estados Unidos e China, e é atualmente líder mundial de exportação nesse setor, com expectativa de exportação segundo a CONAB de 36 milhões de toneladas do grão sairão do país entre 2024 e 2025. Em Minas Gerais, o crescimento da produção de milho se desenvolve principalmente ao aumento do rendimento das atividades, embora não ocorra de maneira uniforme em todas as regiões do estado (Javier Cremades García et al., 2006). A região do Sul de Minas foi a que mais plantou milho em todo estado, representando 19,7% de todo milho plantando no estado, sendo aproximadamente 252 mil hectares.

No entanto segundo dados da CONAB (2024) o Brasil apresentou uma redução de 10,7 % em área planta na safra de 2023/2024 em comparação com a safra anterior, dentre os fatores que contribuíram para a baixas, o principal desafio enfrentado por produtores está a instabilidades climáticas enfrentadas nos últimos anos. Com os desafios impostos, outras alternativas vêm sendo implementadas para a retomada da produção mediante aos desafios climáticos enfrentados. A implementação da Agricultura de precisão vem como uma ferramenta para maximizar a produção e otimizar o uso de insumos agrícolas (Tschiedel; Ferreira, 2002).

Dentre as fases de produção do milho o plantio é uma etapa crucial, pois nela vai se definir todas as situações para o sucesso da lavoura, desde escolha da semente, tipo de cultivar, espaçamento entre plantas, densidade de plantas, sentido de plantio, profundidade que serão alocadas as sementes, época de plantio, podendo ser implementada na primeira safra que ocorre plantio entre os meses de outubro e novembro, ou segunda safra que ocorre entre os meses de janeiro a março (Miranda, 2019).

OBJETIVOS

Utilizar mapas de semeadura e colheita para investigar a variabilidade na produção de milho. Verificar se existe relação entre a densidade e a produtividade através das análises de mapas de plantio e colheita. Além disso definir os limites da variação da densidade de plantas de forma que não afete a produtividade do milho.

MATERIAL E MÉTODOS

O estudo foi realizado no município de Luminárias, Minas Gerias, localizada nas seguintes coordenadas 21° 30' 39"S e 44° 54' 10"O, com altitude média de 1141 m e área territorial de 500,143km², estando situada entre a região Campo Das Vertentes e o Sul de Minas. A lavoura analisada, é uma área comercial da fazenda Mato Verde, localizada na Zona Rural, sendo utilizado uma parte do talhão denominado de C14, com uma área de aproximadamente 14,3 hectares, com declividade média de 13,5%, localizado nas seguintes coordenadas 21°29'6.54"S e 44°49'9.15"O (Figura 1).



FIGURA 1. Talhão C14, Fazenda Mato Verde

O híbrido P2501 (Pioneer), cultivar de ciclo precoce com excelente potencial produtivo, sendo utilizado uma taxa alvo de densidade de plantas de 75.000 plantas ha. A operação de plantio foi realizada no dia 02/10/2022 utilizando de um conjunto da marca John Deere (Figura 2), sendo o trator modelo 7230J equipados de fábrica com receptor GNSS StarFire 6000, monitor GS3 2630 e piloto automático AutoTrac, e a semeadora do modelo John Deere 1113, com 14 linhas de plantio, com espaçamento de 0,5 metros entre as linhas de plantio e tecnologia SeedStar 2 que fornece em tempo real informações agronômicas precisas da operação de plantio.

RESULTADOS E DISCUSSÃO

A partir da interpolação dos dados obtidos, podemos analisar os resultados gerados pela operação de semeadura no campo, onde foi selecionado uma taxa alvo de 75.000 sementes por hectare, mas devido a diversos fatores como regulagem da semeadora, velocidade de trabalho, declividade da área, entre outros, fazem com que ocorram variação na taxa aplicada, sendo encontrado variações de 68.172 (sem/ha) como menor taxa aplica até 77.863 (sem/ha) como maior taxa aplicada, sendo a taxa aplicada média de 75.447 (sem/ha).

Para criação do mapa temático foram separados em diferentes faixas de classificação sendo elas, até 68.172 (sem/ha) até 74.909 (sem/ha), representando aproximadamente 3,4 hectares cerca de 23,7% da área total, de 74.909 (sem/ha) até 76.100 (sem/ha) representando aproximadamente 2,5 hectares cerca de 18% da área total, de 76.100 (sem/ha) até 76600 (sem/ha), representando aproximadamente 1,7 hectares cerca 12%, de 76600 até 77863, representando aproximadamente 6,5 hectares cerca de 46,4% da área total.

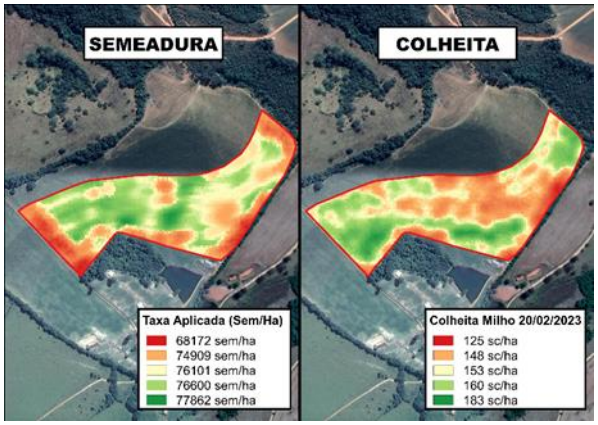


FIGURA 3 - Comparação dos Mapas de Semeadura e Produtividade

A partir da elaboração dos mapas temáticos de semeadura e de produtividade podemos relacionar as informações obtidas para realizar a comparação entre os mapas, e conhecer a influência da

variabilidade da semeadura na variabilidade da produtividade final da lavoura. Fazendo uma análise visual primeiramente através da figura 3, podemos observar as áreas onde tem as maiores e menores a taxas de locação de sementes, e as áreas de maior e menor produtividade (figura 4).

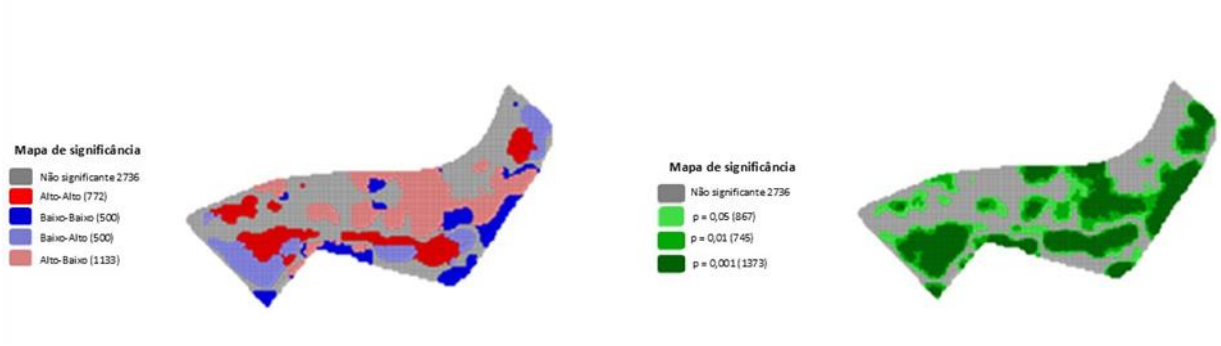


FIGURA 4. Comparação dos Mapas de Semeadura e Produtividade.

Avaliando a qualidade do processo de semeadura, utilizando como base a população de plantas, onde foi utilizado 75.000 plantas por hectare como taxa alvo da aplicação figura 4. A carta de controle tem como função demostrar a variabilidade desse processo, de modo a classificar as variações aceitáveis. Neste caso, são definidas três retas, onde a localizada no meio representa o valor médio, que para essa operação foi encontrado o valor de 75477 sementes por hectare, a reta abaixo representa o limite de controle inferior, que foi definido no valor de 74790 sementes por hectare, e a reta acima representa o limite de controle superior, no valor de 76103 sementes por hectare, como podemos observar na figura 5.

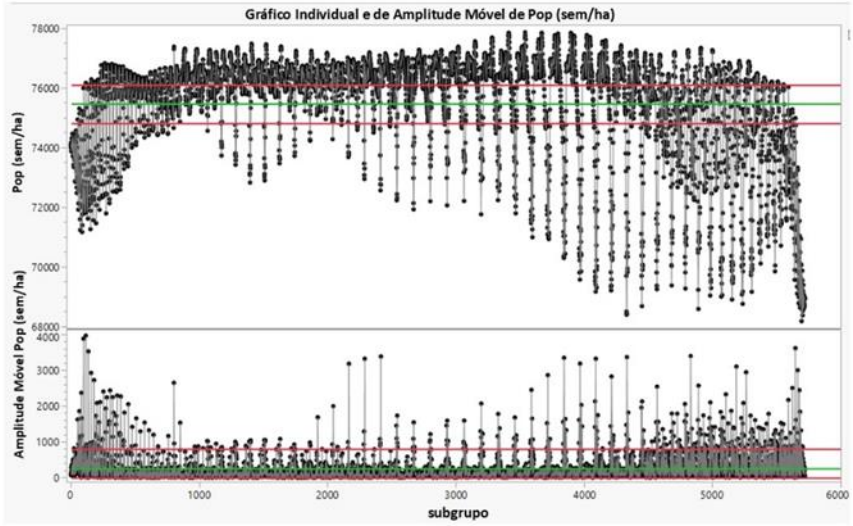


FIGURA 5 - Carta de Controle IMR da População de Plantas

Dessa forma os pontos localizados fora dos limites definidos são considerados como fora do padrão estatístico de controle, como formar de manter a operação mais estável possível sem que ocorra muita variação sobre a taxa alvo definida. A segunda parte da carta de controle Moving Range, representa a amplitude móvel que são a diferença entre cada leitura dos dados, onde seu valor médio foi de 246 sementes por hectare, e foi considerado seu limite superior como 806 sementes por hectare, dessa forma os pontos localizados fora do limite superior representa que a diferença entre leituras de um ponto para o outro saiu do padrão de controle estatístico ideal.

CONCLUSÃO

Os resultados destacam a importância crucial da densidade de semeadura, evidenciando sua relação direta com a produtividade do milho. A influência significativa entre a densidade de plantas e a produtividade sugere que o ajuste adequado da quantidade de sementes por hectare pode otimizar custos e aumentar a produção. Esses achados ressaltam a importância de uma calibração precisa da semeadora. Além disso, foi demonstrado o desempenho eficaz dos sistemas de informações geográficas (SIG) no monitoramento e na compreensão da variabilidade espacial.

AGRADECIMENTOS

Agradecemos ao Departamento de Agricultura da Universidade Federal de Lavras e a CAPES.

REFERÊNCIAS

SILVA, Luiz Eduardo Bezerra; SILVA, José Crisólogo de Sales; SOUZA, Willian Cleisson Lopes de; LIMA, Luan Lucas Cardoso; SANTOS, Rafael Lima Vieira dos. Desenvolvimento da cultura do milho (*Zea mays L.*): revisão de literatura. **Diversitas Journal**, v. 5, n. 3, p. 1636-1657, 2020. DOI: 10.17648/diversitas-journal-v5i3-869. Acesso em: 24 set. 2024.

CONAB. Histórico do milho - Minas Gerais. Disponível em : < https://www.conab.gov.br?/informações-agro /a-faça -eu-agro-e -e/analisar -regional -do-mercado -agropecuário /analisar -regional -mg -milho. Acesso em: 14 set. 2024.

MIRANDA, GV *et al*. Milho (Zea *mays L.*). **Culturas: manual de tecnologias agrícolas**. Belo Horizonte: Epamig, 2019. p. 628-649.

GARCIA, J. C.; DE OLIVEIRA DUARTEÊ, M. J. M. J. **Importância do milho em Minas Gerais**. Disponível em:<https://www.alice.cnptia.embrapa.br/alice/bitstream/1/Importanciamilho>Acesso em: 24 set. 2024.

MAPEAMENTO DE ATRIBUTOS DO SOLO POR MEIO DA KRIGAGEM COM DERIVA EXTERNA E INFORMAÇÕES AUXILIARES PROVINDAS DA AGRICULTURA DE PRECISÃO

Júlia de Paula Tavares do Nascimento [1]; Laura Delgado Bejarano [2]; Lucas Rios do Amaral [3]
[1]Graduanda. Campinas - SP. Faculdade de Engenharia Agrícola - FEAGRI, Universidade Estadual de Campinas, UNICAMP, Campinas; [2]Mestranda. Campinas - SP. Faculdade de Engenharia Agrícola - FEAGRI, Universidade Estadual de Campinas, UNICAMP, Campinas; [3]Professor Associado. Campinas - SP. Faculdade de Engenharia Agrícola - FEAGRI, Universidade Estadual de Campinas, UNICAMP, Campinas

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
Ainda há poucos estudos utilizando a Krigagem com Deriva Externa (KED) na agricultura de precisão, mas apresenta resultados promissores. O objetivo deste estudo foi investigar o impacto da inclusão de covariáveis oriundas de sensoriamento no desempenho da KED para o mapeamento de propriedades do solo. Utilizamos uma área comercial de grãos de 107 ha, coletando uma amostra composta a cada 3 ha. As variáveis do solo para mapeamento foram: matéria orgânica (MO) e teor de argila, enquanto as variáveis auxiliares foram: susceptibilidade magnética (SM) e condutividade elétrica aparente (CEa), saturação do espaço HIS para imagem de solo descoberto (sHIS), elevação (Elev) e declividade (Slope) do terreno. Observou-se melhor predição dos atributos do solo nos mapas gerados por KED em comparação à Krigagem Ordinária (KO). Porém, em situações onde os atributos meta apresentam alta dependência espacial, o uso de modelos complexos não se justificam, visto que a interpolação por KO já conseguiria fazer uma predição satisfatória. É importante destacar que no caso de uma variável com dependência espacial fraca, como foi o caso da MO, a KED apresenta bom desempenho ao adicionar covariáveis, embora esse desempenho seja otimizado apenas até um certo limite de covariáveis, além do qual a adição de mais covariáveis pode, na verdade, prejudicar o desempenho do modelo. A KED pode ser muito útil em levantamentos de solo que envolvam uma densidade amostral baixa, barateando o processo ao mesmo tempo que pode entregar maior exatidão no mapeamento.

PALAVRAS-CHAVE: Geoestatística; Interpolação; Mapeamento digital de solos

ABSTRACT
There are still few studies using Kriging with External Drift (KED) in precision agriculture, but it shows promising results. The aim of this study was to investigate the impact of including covariates from sensing on the performance of KED for mapping soil properties. We used a commercial grain area of 107 ha, collecting a composite sample every 3 ha. The soil variables for mapping were: organic matter (OM) and clay content, while the auxiliary variables were: magnetic susceptibility (MS) and apparent electrical conductivity (aEC), saturation of the HIS space for bare soil image (sHIS), elevation (Elev) and slope of the terrain. Better prediction of soil attributes was observed in the maps generated by KED compared to Ordinary Kriging (OK). However, in situations where the target attributes have high spatial dependence, the use of complex models is not justified, since interpolation by KO would already be able to make a satisfactory prediction. It is important to note that in the case of a variable with weak spatial dependence, as was the case with MO, KED performs well when adding covariates, although this performance is only optimized up to a certain limit of covariates, beyond which the addition of more covariates can actually harm the model's performance. KED can be very useful in soil surveys that involve a low sample density, making the process cheaper while delivering greater mapping accuracy.

KEYWORDS: Geostatistics; Interpolation; Digital soil mapping

INTRODUÇÃO

Uma das mais notáveis aplicações da agricultura de precisão é a criação de mapas de fertilidade, os quais servem de base para a elaboração de mapas de prescrição de fertilizantes. Esses mapas são construídos a partir de amostras de solo georreferenciadas coletadas de forma sistemática ao longo das áreas agrícolas e estimam valores em locais não amostrados por meio de métodos de interpolação geoespacial (Colaço e Molin, 2014; Li e Heap, 2011). A construção dos mapas geralmente requer uma alta densidade amostral, a fim de obter uma representação acurada da variabilidade espacial dos atributos do solo (Pereira et al, 2022), o que muitas vezes é considerado muito caro e trabalhoso pelo agricultor ou prestador de serviço. O uso de interpoladores que utilizam métodos multivariados surge como resposta para esse problema (Goovaerts, 2000), sendo que mediante um conhecimento prévio da área que pode ser obtido por informações auxiliares, como dados de sensoriamento remoto e informações topográficas, é possível melhorar a qualidade dos mapas das propriedades do solo obtidos (Pusch et.al, 2022), desde que as variáveis auxiliares apresentem certo grau de correlação com a variável principal. A Krigagem com Deriva Externa (KED) é um método de interpolação que já foi utilizado em algumas pesquisas que apresentaram resultados promissores (Rocha et al, 2009; Pusch et al, 2021; Sanches et al, 2018). No entanto, ainda não é claro quais as características que os dados precisam ter e quais os níveis de relação necessária entre variáveis auxiliares e principal para trazerem ganhos no mapeamento de atributos do solo.

OBJETIVOS

Dito isso, o trabalho focou em investigar o impacto da inclusão de covariáveis oriundas de sensoriamento no desempenho da KED para mapeamento de propriedades do solo.

MATERIAL E MÉTODOS

A área de estudo se localizada no município de Cosmópolis - SP, possui aproximadamente 107 ha (Figura 1), com predominância de Latossolo vermelho muito argiloso e é cultivada com grãos. A amostragem de solo foi realizada na densidade de seis amostras por hectare com quadriciclo instrumentado com broca. Para representar cada amostra, coletamos seis subamostras num raio de cinco metros do ponto central, com profundidade de coleta de 0-20 cm. Procurando um cenário representativo de amostragem usado no Brasil pelos agricultores e empresas de agricultura de precisão, foram selecionadas manualmente amostras, de forma a resultar em uma grade amostral com densidade de uma amostra a cada três hectares. Assim, as amostras que não foram usadas na interpolação serviram como pontos de validação (Figura 1).

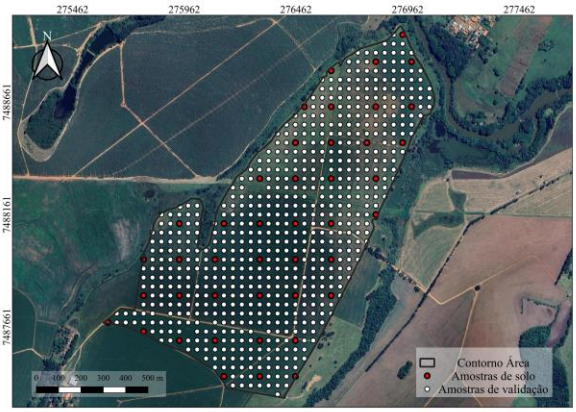


FIGURA 1. Área de estudo e representação espacial das amostras usadas nas interpolações e como amostras de validação. Imagem base: Google satélite.

Foram investigados os conteúdos de argila e matéria orgânica (MO), já que são atributos pouco influenciados pelo manejo e que regem a dinâmica dos solos agrícolas. As covariáveis exploradas foram: susceptibilidade magnética (SM), condutividade elétrica aparente (CEa) saturação do espaço HIS para imagem de solo descoberto chamada de pureza da cor (sHIS), elevação e declividade (Slope).

A KED busca interpolar valores de uma variável de interesse (propriedades do solo) a partir das variáveis auxiliares obtidas em maior densidade, desde que essas apresentem certa correlação com a variável de interesse (Pusch et al, 2021). Assim, os valores de cada uma das covariáveis ??do estudo foram extraídos para as coordenadas dos pontos amostrais, permitindo a realização da correlação de Spearman para identificar a relação entre as covariáveis e as variáveis de estudo (argila e MO). As covariáveis foram adicionadas nos modelos de KED conforme a ordem decrescente de correlação. Como algumas covariáveis apresentaram correlação entre si, foram consideradas colineares aquelas com |r|>0,70 (Dormann et al, 2013), e a que apresentava menor valor de correlação com a variável objetivo foi adicionada ao final do modelo. O Índice de Moran (IM) foi calculado para determinar o nível de dependência espacial dos parâmetros. Por último, foram utilizados o coeficiente de determinação (R2), erro absoluto médio (MAE) e o erro médio quadrático (RMSE) das predições por KED nos pontos de validação.

RESULTADOS E DISCUSSÃO

Na Tabela 1 pode-se observar que a CEa e SM apresentaram colinearidade (r = -0,88); nesse caso, não é recomendado usar as duas no modelo de predição, já que pode aumentar a variância da regressão (Dormann et al., 2013). No caso da argila, a CEa e a SM apresentaram o mesmo nível de correlação com essa variável e, portanto, optamos por incluir apenas a SM. Para o caso do modelo de MO, a SM foi a última covariável adicionada, devido a sua baixa correlação com a variável principal.

TABELA 1. Correlação de Spearman entre as variáveis analisadas. Em vermelho as correlações da matéria orgânica com a variáveis auxiliares e, em azul, as correlações da argila.

	MO	CEa	SM	sHIS	Elev	Slope
Argila	1	0,61	-0,61	-0,49	-0,07	0,07
CEa	0,46	1	-0,88	-0,06	-0,58	0,09
SM	0,45	-0,88	1	0,09	0,55	-0,07

sHIS	-0,12	-0,06	0,09	1	-0.49	0,10
Elev	-0,16	-0,58	0,55	-0,49	1	-0,25
Slope	-0,03	0,09	-0,07	0,10	-0,25	1

Na tabela 2 são apresentadas as covariáveis que foram adicionadas em cada modelo. Avaliando as métricas da validação cruzada realizada, percebe-se um melhor resultado na predição de argila utilizando apenas a covariável de SM; no entanto, não se observa um aumento relevante na qualidade do modelo comparado com a KO, que não usa covariáveis, o que não justificaria a utilização de covariáveis e modelos multivariados como a KED. Isso ocorre devido a argila ter apresentado alta dependência espacial (IM=0,37), portanto, a KO consegue fazer boa precisão.

Já quanto à predição de MO, a KO não apresentou um bom ajuste (Tabela 2) e, adicionado as covariáveis CEa e elevação, se observa um aumento de 0,16 no R2. Neste caso, essa variável apresentou uma dependência espacial menor que a argila (IM=0,04), apresentando comportamento espacial bastante aleatório, mostrando que a distância de amostragem não é suficiente para capturar a variabilidade. Contudo, ao utilizar a KED, nota-se que as covariáveis, as quais são amostradas de forma densa, ajudam o modelo, aumentando o R2 para 0,20, o que faz com que a KED seja uma melhor opção para a interpolação (Snepvangers et al, 2003). No entanto, após adicionar a terceira covariável (Tabela 2), o desempenho das predições é impactado negativamente (R2 de 0,18), indicando que não é necessário usar todas as informações disponíveis, já que só as covariáveis que estão altamente correlacionadas com o parâmetro de estudo tem a capacidade de explicar a variabilidade deles, do contrário não contribuem com o modelo.

TABELA 2. Modelos de interpolação usados na KED para os dois atributos de solo e desempenho das predições mensurados nas amostras de validação

Variável	Modelo	R^2	RMSE	MAE
Argila (g/kg)	~1	0.85	41.96	32.60
	~SM	0.86	41.30	31.83
	~SM+sHIS	0.84	43.76	33.85
	~SM+SY+Elev	0.84	43.26	33.40
	~SM+SY+Elev+Slope	0.83	44.65	34.41
	~SM+SY+Elev+Slope+CEa	0.83	44.50	34.40
MO (gm/dm3)	~1	0.04	3.28	2.57
	~CEa	0.18	3.03	2.41
	~CEa+Elev	0.20	2.98	2.38
	~CEa+Elev+sHIS	0.18	3.03	2.40
	~CEa+Elev+SY+Slope	0.18	3.03	2.40
	~CEa+Elev+SY+Slope+SM	0.15	3.09	2.45

De forma gráfica, pode-se visualizar que nos mapas de argila não se observa uma variação evidente após a inclusão da terceira covariável e, dados os valores das métricas apresentados anteriormente,

observa-se que o mapa de argila da figura 2B, que foi gerado com o modelo escolhido, tem maior detalhe em comparação ao gerado por KO (Figura 2A). Contudo, devido à alta dependência espacial da argila, a KO já representa bem a variabilidade espacial da argila.

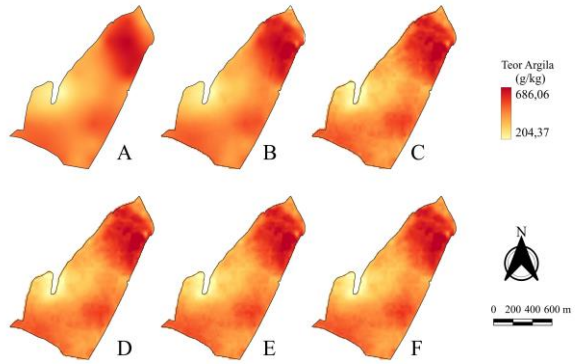


FIGURA 2. Mapas de interpolação de teor de argila aumentando o número de covariáveis. A. Sem covariáveis (Krigagem ordinária - OK); B. SM; C. SM+sHIS; D. SM+SY+Elev; E. SM+sHIS+Elev+Slope; F. SM+sHIS+Elev+Slope+CEa.

No caso da variabilidade espacial da matéria orgânica, observamos que a figura 3B, selecionada como o melhor modelo, apresenta um comportamento similar, porém mais detalhado em comparação com o modelo de KO (Figura 3A), o qual não consegue representar as manchas de variabilidade, principalmente os maiores teores observados na parte norte da área. Além disso, como a CEa foi a covariável com maior importância no modelo, a linha que cruza a área no sentido norte-sul é característico do mapa de CEa obtido (não apresentado), ocasionado por alguma variação no sinal medido, mas sem causa determinada até então.

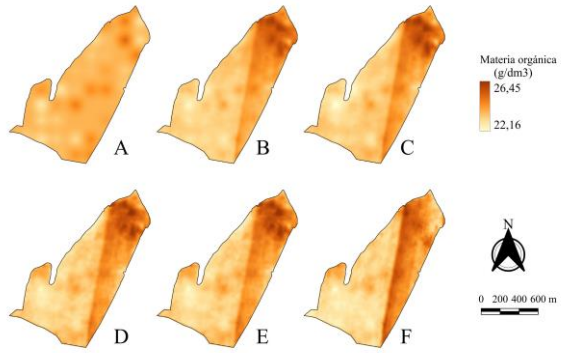


FIGURA 3. Mapas de interpolação de conteúdo de matéria orgânica aumentando o número de covariáveis. A. Sem covariáveis (Krigagem ordinária); B. CEa; C. CEa+Elev; D. CEa+Elev+sHIS; E. CEa+sHIS+Elev+Slope; F. CEa+ Elev+sHIS+Slope+SM.

CONCLUSÃO

A KED é mais eficaz que a KO quando o atributo meta do solo tem baixa dependência espacial, pois as covariáveis ajudam a modelar a variabilidade espacial que a distância de amostragem não consegue captar. Porém, é essencial observar a correlação com as variáveis auxiliares.

AGRADECIMENTOS

Ao mestrando Derlei D. Melo e ao técnico Thiago L. Brasco pela coleta dos dados de solo utilizados e à doutoranda Agda L. G. Oliveira pela valiosa ajuda no entendimento das funções e scripts usados nas análises dos dados. Agradecemos à FAPESP pelo apoio financeiro (processo n° 2022/03160-8) e pela bolsa de mestrado para a segunda autora (processo n° 2024/01557-3).

REFERÊNCIAS

COLAÇO, André F.; MOLIN, José P. Amostragem Georreferenciada. Agricultura de Precisão: Boletim Técnico. Piracicaba, 2014. Disponível em: https://acortar.link/WmJdfs

DORMANN, Carsten F. et al. Collinearity: A review of methods to deal with it and a simulation study evaluating their performance. Ecography, , v. 36, n. 1, p. 27-46, 2013.

GOOVAERTS, P. Geostatistical approaches for incorporating elevation into the spatial interpolation of rainfall. Journal of Hydrology, v. 228, p. 113-129, 2000.

LI J.; HEAP, A. D. A review of comparative studies of spatial interpolation methods in environmental sciences: Performance and impact factors. Ecological Informatics, v. 6, n.1, p. 228-241, 2011.

PEREIRA, G.W.; VALENTE, D.S.M.; DE QUEIROZ, D.M.; SANTOS, N.T.; FERNANDES-FILHO, E.I. Soil mapping for precision agriculture using support vector machines combined with inverse distance weighting. Precision Agriculture, v.23, p.1189 - 1204, 2022.

PUSCH, M.; OLIVEIRA, A. L. G., FONTENELLI; J. V., & AMARAL, L. R. SOIL PROPERTIES MAPPING USING PROXIMAL AND REMOTE SENSING AS COVARIATE. Engenharia Agrícola, v.41, n.6, p.634 - 642, 2021.

PUSCH, M.; SAMUEL-ROSA, A.; OLIVEIRA, A.L.G.; MAGALHÃES, P.S.G.; AMARAL, L.R. Improving soil property maps for precision agriculture in the presence of outliers using covariates. Precision Agriculture, v. 23, p.1575-1603, 2022.

ROCHA, M. M.; YAMAMOTO, J. K.; FONTELES, H. R. N. Cokrigagem Ordinária versus Krigagem com Deriva Externa: aplicações para a avaliação do nível potenciométrico em um aquífero livre. Geologia USP. Série Científica, v.9, n.1, p. 73-84, 2009.

SANCHES, G. M.; MAGALHÃES, P. S. G.; REMACRE, A . Z.; FRANCO, H. C. J. Potential of apparent soil electrical conductivity to describe the soil pH and improve lime application in a clayey soil. Soil and Tillage Research, v. 175, p. 217-225, 2018.

SNEPVANGERS, J.J.J.C.; HEUVElLINK, G.B.M.; HUISMAN, J.A. Soil water content interpolation using spatio-temporal kriging with external drift. Geoderma, v. 112, p. 253 - 271, 2003.

DELINEAMENTO DE ZONAS DE MANEJO E AVALIAÇÃO DE EXPERIMENTAÇÃO ON-FARM PARA DIFERENTES POPULAÇÕES DE SEMENTES UTILIZANDO SENSORIAMENTO REMOTO E PROXIMAL NA CULTURA DO ALGODÃO

Eduardo Antonio Speranza [1]; Ivani de Oliveira Negrão Lopes [2]; Carlos Manoel Pedro Vaz [3]; Julio Cezar Franchini dos Santos [2]; João de Mendonça Naime [3]; Ricardo Yassushi Inamasu [3]; Sérgio das Chagas [4]

[1]Analista. Campinas, SP. Embrapa Agricultura Digital; [2]Pesquisador. Londrina, PR. Embrapa Soja; [3]Pesquisador. São Carlos, SP. Embrapa Instrumentação; [4]Coordenador de Agricultura Digital. Sapezal, MT. Grupo Amaggi

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

O Estado de Mato Grosso lidera a produção nacional de algodão, destacando-se por investimentos em tecnologia e práticas de manejo. O uso de agricultura de precisão e digital é fundamental nesse avanço, especialmente no processo de delineamento de zonas de manejo baseado em dados espectrais. O sensoriamento remoto e a experimentação *on-farm* são essenciais para a gestão eficiente da lavoura, reduzindo custos e impactos ambientais. Neste contexto, o estudo teve como objetivos utilizar índices de vegetação para definir zonas de manejo e determinar períodos de desenvolvimento da cultura mais adequados para estimar a produtividade do algodão, em função de variações na densidade populacional. Para isso, o sensoriamento remoto, utilizando o histórico de imagens orbitais dos últimos cinco anos, foi crucial para a definição de zonas de manejo com diferente potencial produtivo. Experimentos *on-farm* com níveis de densidade populacional, direcionados às zonas de manejo identificadas, mostraram que as imagens coletadas no período de 30 a 60 dias são as que melhor representam a variabilidade da população de plantas. Os períodos mais indicados para estimativas mais acuradas da produtividade variaram entre as zonas de manejo, sendo mais precoce (120 a 150 dias) na zona mais argilosa do que na zona arenosa (mais de 150 dias).

PALAVRAS-CHAVE: Índices de vegetação; Florestas Aleatórias; Quadrado Latino

ABSTRACT

The State of Mato Grosso leads national cotton production, standing out for its investments in technology and management practices. The use of precision and digital agriculture is underlying in this progress, especially in the process of delineating management zones based on spectral data. Remote sensing and on-farm experimentation are essential for efficient crop management, reducing costs and environmental impacts. In this context, the study aimed to use vegetation indices to define management zones and determine the most appropriate crop development periods to estimate cotton yield, depending on variations in population density. To achieve this, remote sensing, using the history of orbital images from the last five years was crucial for defining management zones with different yield potential. On-farm experiments with population density levels, targeted at the identified management zones, showed that the images collected over a period of 30 to 60 days are those that best represent the variability of the plant population. The most suitable periods for more accurate estimates of yield varied between management zones, being earlier (120 to 150 days) in the more clayey zone than in the sandy zone (more than 150 days).

KEYWORDS: ;;

INTRODUÇÃO

A produção de algodão no estado do Mato Grosso tem sido uma das principais atividades agrícolas da região, apresentando um notável crescimento nos últimos anos. Na safra 2021/2022, o estado manteve a posição de maior produtor de algodão do Brasil, alcançando uma produção de 4,549 milhões de toneladas de algodão em caroço, representando 72% da produção nacional (ABRAPA, 2024). Esse cenário pode ser atribuído a uma série de fatores, incluindo investimentos em tecnologia e pesquisa, adoção de cultivares resistentes a pragas e doenças e a utilização de boas práticas de manejo. Nesse contexto de avanços agrícolas, as ferramentas de agricultura de precisão (AP) e agricultura digital (AD) emergem como elementos-chave para otimizar o uso de recursos agrícolas e incrementar a produtividade (BASSOI et al., 2019). Dentre essas ferramentas, destaca-se o delineamento de zonas de manejo (ZM). O conceito de ZM sugere a subdivisão de um talhão de produção em subáreas com diferentes potenciais produtivos com base em bancos de dados espaço-temporais de atributos do solo e da cultura capazes de identificar a variabilidade espacial não-antrópica da área estudada (DOERGE, 1999; MOLIN et al., 2015). Nos últimos anos as áreas de sensoriamento remoto, análise de dados, inteligência artificial e automação têm impulsionado o uso das ZM para gestão da lavoura. Em se tratando de sensoriamento remoto, com o avanço tecnológico e a disponibilidade de dados com alta resolução espacial e temporal, os produtores têm utilizado cada vez mais esse tipo de informação para o monitoramento de infestações por pragas e saúde da planta, padrões de crescimento, variabilidades do solo, dentre outras (SISHODIA, et al., 2020). Adicionalmente, a experimentação *on-farm* (ou na fazenda) em AP se tornou uma técnica fundamental para os produtores que buscam uma gestão mais eficiente da lavoura. Essa abordagem envolve a realização de experimentos diretamente nas áreas de produção, permitindo avaliar e ajustar variáveis como fertilidade do solo, manejo de irrigação, aplicação de defensivos, escolha de cultivares e taxas de população de plantas de forma personalizada e adaptada às condições específicas de cada talhão ou ZM. Ao coletar dados *in loco* e aplicar análises estatísticas avançadas, os produtores podem tomar decisões mais adequadas, reduzindo custos, aumentando a produtividade e minimizando impactos ambientais, contribuindo assim para uma agricultura mais sustentável e rentável (SHIRATSUCHI et al., 2019).

OBJETIVOS

Este estudo teve como objetivos utilizar índices de vegetação para definir zonas de manejo e determinar períodos de desenvolvimento da cultura mais adequados para a estimativa da produtividade do algodão, em função de variações na densidade populacional da cultura em experimento *on-farm* realizado em talhão comercial.

MATERIAL E MÉTODOS

A área de estudo deste trabalho compreende um talhão de produção comercial de algodão safrinha (cultivado após a colheita da soja) com área total de aproximadamente 290 ha, localizado na Fazenda Tucunaré, em Sapezal-MT, com coordenadas geográficas centrais 288458 W e 8488880 S, considerando o sistema de referência de coordenadas WGS 84 / UTM Zona 21 S, pertencente ao grupo Amaggi (FIGURA 1.I).

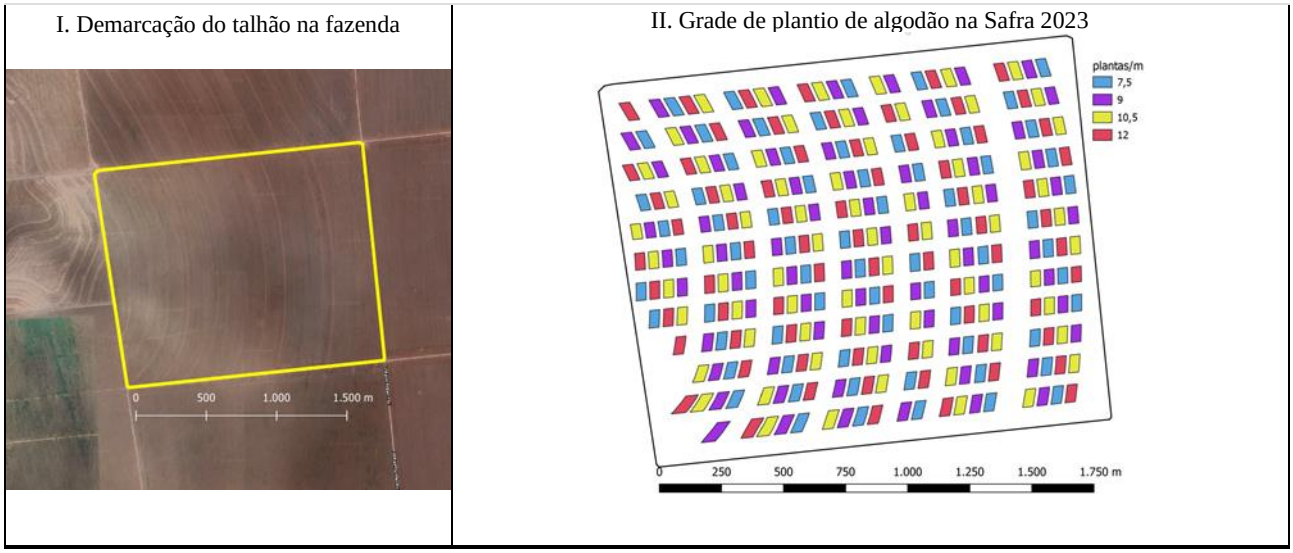


FIGURA 1. Talhão experimental (delimitado em amarelo) que compreende a área de estudo utilizada (I); e o mesmo talhão, exibindo a grade de experimental de plantio utilizada (II). Imagem: Google Maps.

O plantio do algodão foi realizado em todo o talhão com uma densidade de plantas por metro, conforme ilustrado na Figura 1.II. Esta figura mostra diversas possibilidades para tratar parcelas virtuais contíguas como um experimento em quadrado latino (MONTGOMERY, 2017). A delimitação das parcelas formando múltiplos experimentos é realizada posteriormente, após a análise das condições de homogeneidade do talhão em relação ao potencial produtivo. Para determinar essas condições, foram geradas zonas de manejo com base na variabilidade espacial da área, que foi detectada por índices de vegetação (IV) obtidos a partir de imagens de sensoriamento remoto durante um período de cinco anos anteriores à execução do experimento (de 2017 a 2022).

Durante todo esse período, o talhão estudado produziu soja como cultura de verão e algodão de segunda safra como cultura de inverno. Para o delineamento de zonas de manejo, foram utilizadas composições de índices de vegetação, tomando-se os valores médios de cada pixel interno à área. Essas composições foram geradas por um *script* para a plataforma Google Earth Engine (GEE), utilizando a série temporal harmonizada do satélite Sentinel-2, disponível para o período estudado, independentemente de estádio fenológico das culturas ou períodos de solo exposto (EARTH ENGINE DATA CATALOG, 2024). O *script* utiliza a coleção "Cloud_Score_Plus" para eliminar imagens com nuvens e sombras de nuvens na área estudada, garantindo melhor qualidade aos dados obtidos.

Embora vários índices de vegetação tenham sido avaliados ao longo do período citado, apenas dois foram escolhidos para o delineamento das ZM: EVI (Huete et al.,2002), que apresentou maior correlação linear positiva com a produtividade do algodoeiro em relação aos demais índices; e PSRI (Merzlyak, et al., 1999), que apresentou maior correlação linear negativa (dados não mostrados). O EVI (*Enhanced Vegetation Index*) é uma variação do NDVI (*Normalized Difference Vegetation Index*), onde são considerados fatores como a influência do solo e da atmosfera na detecção da biomassa da vegetação. Já o PSRI (*Plant Scenescence Reflectance Index*) possui uma característica particular que auxilia na detecção do estágio de senescência das plantas e, consequentemente, na identificação da ocorrência de estresses ambientais.

A FIGURA 2 apresenta os mapas dos índices de vegetação EVI e PSRI, consolidados para a área de estudo entre as safras de 2017 a 2022, que foram utilizados no delineamento das zonas de manejo. A figura também inclui o mapa de colheita do algodão da safra de 2023 (kg ha^{-1}), utilizado para avaliar a eficácia das zonas de manejo delineadas e das diferentes populações utilizadas durante o plantio. O mapa de colheita é resultado da fusão dos dados obtidos pelas diferentes colheitadeiras que atuaram no talhão, os quais foram normalizados pela média de produtividade geral.

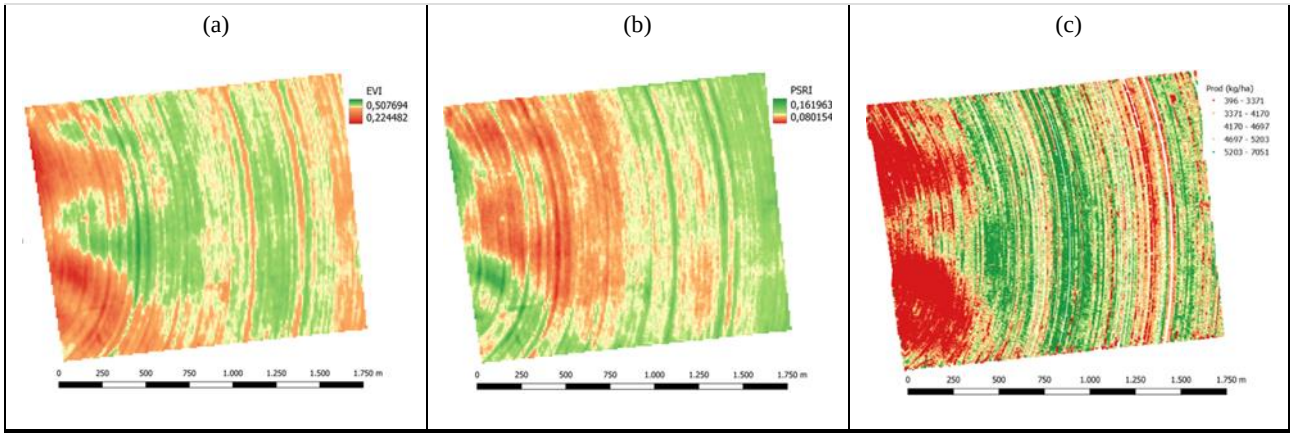


FIGURA 2. Mapas dos valores médios dos índices de vegetação EVI (a) e PSRI (b) entre 2017 e 2022, e mapa de colheita do algodão da safra de 2023 (kg ha^{-1}) para a área de estudo (c).

A partir dos mapas de EVI e PSRI, foram gerados mapas de ZMs para a área, utilizando o algoritmo de agrupamento *k-means* (MACQUEEN, 1967) com diferentes quantidades de grupos. A subdivisão em duas ZM resultou em uma redução de aproximadamente 28% na variância da produtividade, calculada com base no mapa de colheita apresentado na FIGURA 2c e na metodologia descrita por Dobermann et al. (2003). Essa redução é considerável e sugere uma separação significativa entre as duas ZMs, refletindo seus diferentes potenciais produtivos e possibilitando a avaliação do efeito das diferentes populações de sementes utilizadas no experimento. Adicionalmente, com base em amostragens de solo para análise de textura realizadas na área, foi observado que a ZM1 possui, em média, 24% de argila, enquanto a ZM2 possui, em média, 60% de argila (FIGURA 4). Essa diferença na composição de argila no solo é significativa e pode influenciar o desempenho da cultura nas respectivas ZMs.

Para delimitar as parcelas que configurassem um experimento em quadrado latino, foram selecionadas parcelas virtuais de modo que os quatro níveis de sementes por metro (7,5; 9 (padrão); 10,5; e 12) fossem representados conforme a metodologia. Cada nível foi repetido quatro vezes, totalizando 16 parcelas virtuais.

Para as análises realizadas neste trabalho, foram escolhidos quatro quadrados latinos em cada ZM, totalizando 128 parcelas virtuais de aproximadamente 0,3 hectares cada, após filtragem das bordaduras. As parcelas, antes da filtragem, foram definidas por duas passadas da semeadora (54 metros) numa extensão de 120 metros. A FIGURA 3b exibe o mapa com o delineamento dessas 128 parcelas e das duas ZMs. A forma das parcelas virtuais seguiu o mapa de linhas de plantio utilizado, considerando as curvas de nível da área.

O efeito das populações de sementes nas produtividades foi investigado usando o modelo de análise de variância (ANOVA) correspondente ao delineamento em quadrado latino. Em seguida, para estudar a relação entre densidade de plantio e produtividade, foram conduzidas análises de regressão linear sobre os preditores lineares de mínimos quadrados da produtividade, obtidos a partir da ANOVA, em relação ao número de plantas.

(a) (b)

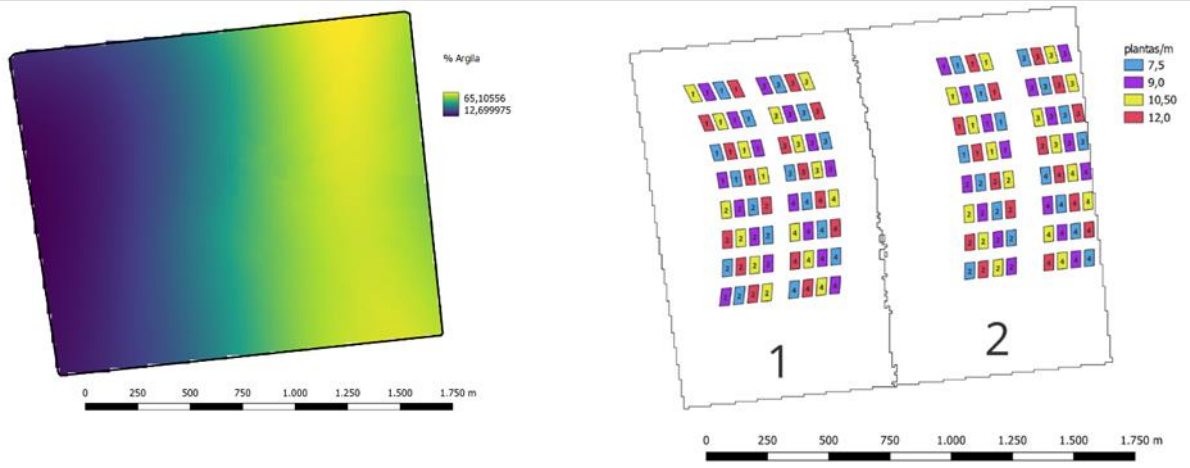


FIGURA 3. Mapa de variabilidade espacial do teor de argila (a) e das zonas de manejo (ZM) definida para a área de estudo, bem como das 128 parcelas virtuais com diferentes populações de plantas, delimitadas com base na metodologia do quadrado latino (b). As cores na legenda indicam o número médio de sementes por metro linear plantadas em cada parcela virtual, e os números de 1 a 4 identificam os experimentos completos para cada ZM.

Para analisar o crescimento das plantas ao longo do ciclo da cultura em diferentes fases fenológicas, foram utilizadas imagens diárias obtidas das constelações de nano satélites Planet® (Planet Labs, PBC). As imagens possuem resolução espacial de 3 m por pixel, o que facilita substancialmente a análise das informações dentro de cada uma das parcelas virtuais utilizadas. Foram escolhidas apenas imagens sem incidência de nuvens e sombras de nuvens, durante o período de março a agosto de 2023, totalizando 24 imagens abrangendo todas as fases fenológicas do desenvolvimento da cultura: vegetativa, botões florais, florescimento e abertura dos capulhos até a colheita. Para esse acompanhamento, foi utilizado o índice de vegetação EVI, devido à sua acurácia já comprovada na estimativa da produtividade do algodão (SIQUEIRA et al., 2024). A FIGURA 4 exibe três exemplos de mapas de EVI obtidos ao longo do ciclo.

Os 24 mapas de EVI foram consolidados em seis diferentes períodos, utilizando o operador de agregação "soma": até 30 dias (P1); de 30 a 60 dias (P2); de 60 a 90 dias (P3); de 90 a 120 dias (P4); de 120 a 150 dias (P5); e mais de 150 dias após o plantio (P6). A partir desses dados, foram obtidas as medidas de importância de variável "*Mean Decrease Accuracy*" e "*Mean Decrease Gini*", considerando como variável alvo a quantidade de plantas por metro como rótulo (classe); e "*%IncMSE*" e "*IncNodePurity*", considerando como variável alvo a produtividade observada, disponibilizadas pelo algoritmo *Random Forest* (Breiman, 2021) - no primeiro caso, atuando como classificador, e no segundo caso, como regressor. Essas medidas foram utilizadas para analisar a capacidade de dados consolidados de EVI, nos seis períodos, em diferenciar a população utilizada e estimar a produtividade obtida em duas ZM com teor de argila distintos.

RESULTADOS E DISCUSSÃO

Os resultados das análises das 24 imagens coletadas nos períodos P1 a P6 revelaram que as imagens capturadas entre 30 e 60 dias após o plantio (P2), destacaram-se por representar melhor a variabilidade da população de plantas na área, em comparação com os outros períodos, em ambas as zonas de manejo. Os gráficos da FIGURA 5.I mostram que a exclusão dos dados desse período contribuiria mais para a redução da eficácia de um modelo de classificação da população de plantas (medidas *MeanDecreaseAccuracy* e *MeanDecreaseGini*) do que a exclusão de quaisquer outros períodos.

Já com relação à produtividade, a FIGURA 5.II nos permite realizar análises distintas considerando as duas ZM definidas para a área de estudo. De acordo com os gráficos dessa figura, o período P6 (mais de 150 dias após o plantio) é o melhor indicativo da produtividade obtida na área menos argilosa. Por outro lado, para a ZM2, mais argilosa, o período mais adequado seria entre 120 e 150 dias (P5).

No caso da produtividade, os resultados mostram que é possível realizar a sua predição com maior precisão e antecedência em área com maior teor de argila (ZM2). Na região mais arenosa (ZM1), a tendência é que ocorram variações maiores ao longo do ciclo, fazendo com que a predição possa ser mais assertiva somente quando estão disponíveis dados em períodos mais próximos da colheita (P5 e P6), devido à sua maior correlação com a produtividade.

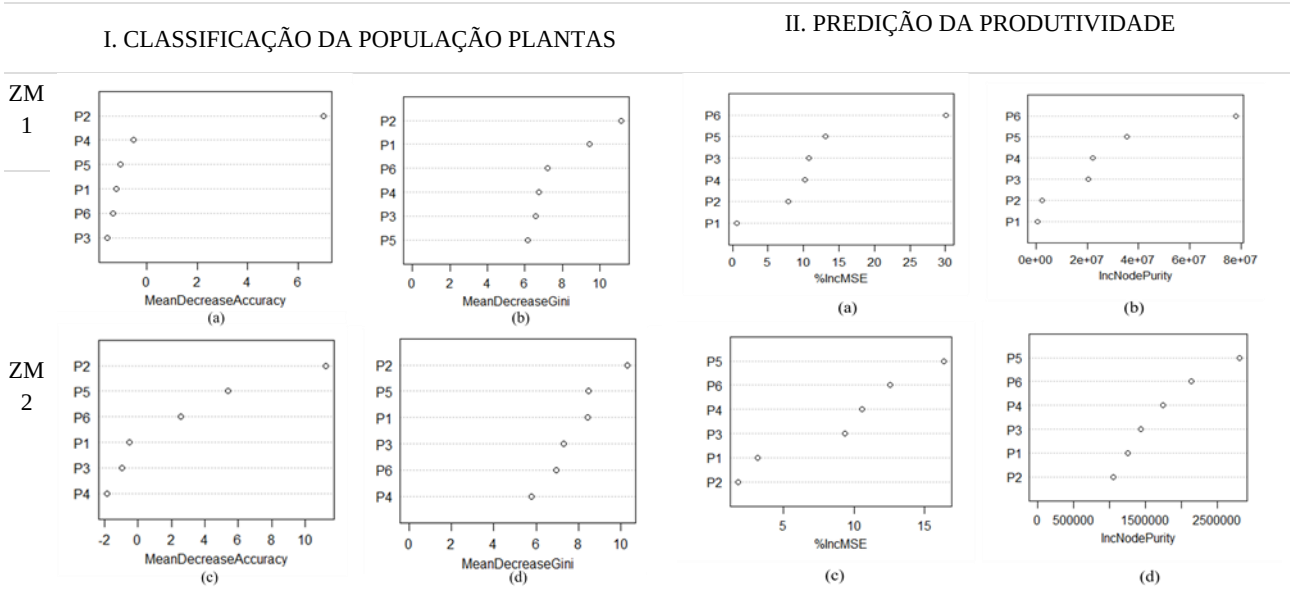


FIGURA 5. Importância do índice EVI acumulado em seis períodos de crescimento (P1 a P6) na classificação da variável alvo plantas por metro e na predição da produtividade, com base nas medidas *MeanDecreaseAccuracy* para a ZM1 (a) e para a ZM2 (c) e *MeanDecreaseGini* para a ZM1 (b) e ZM2 (d).

O número de plantas (NP) contribuiu significativamente para a variação na produtividade apenas no experimento 4, na ZM1, enquanto o efeito foi significativo nos experimentos 2, 3 e 4 na ZM2, conforme mostrado na TABELA 1. Esses resultados indicam que a ZM2 foi mais responsiva ao aumento da população de plantas do que a ZM1. Este efeito é mais evidenciado pelos resultados apresentados na FIGURA 6.

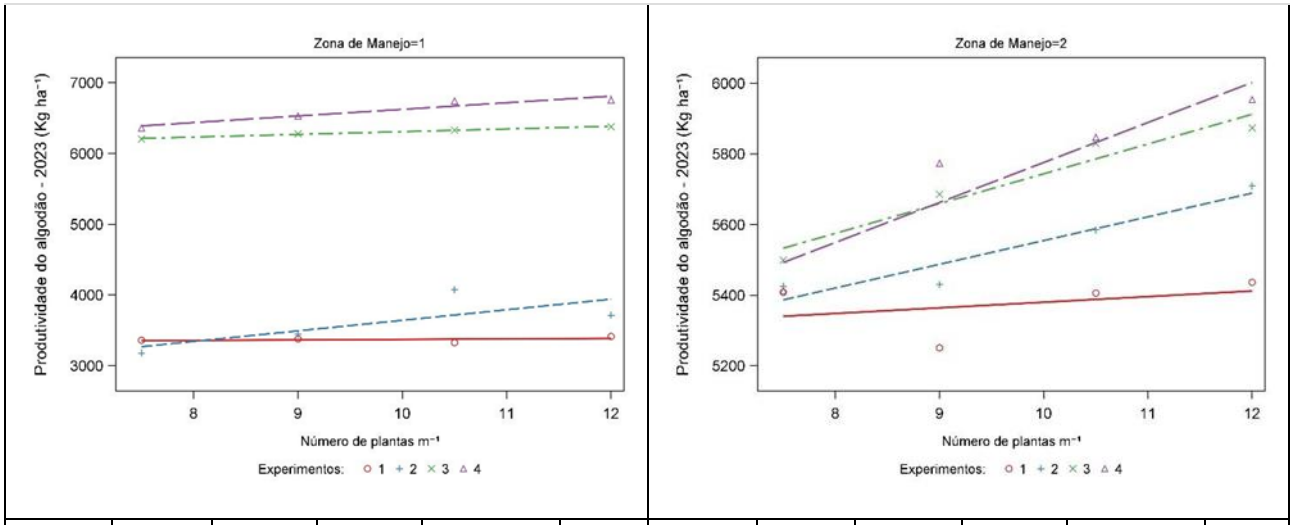
É relevante destacar que o teor de argila pode ter desempenhado um papel importante na definição da produtividade média nas diferentes zonas, sendo a produtividade média maior na ZM2 em relação a ZM1, onde o teor de argila era menor. No entanto, outros fatores não controlados neste estudo, como a variabilidade de nutrientes como P, K, Ca e Mg, também podem ter contribuído para a variabilidade observada na resposta.

TABELA 1. Análise de variâncias de quatro experimentos (Exp), implantados em duas zonas de manejo, segundo o delineamento em quadrado latino, mostrando a contribuição de cada fator para a variação de produtividade (kg ha^{-1}) de algodão em cada talhão. NP=Número de Plantas por metro; FV=Fator de Variação; GL=Grau de Liberdade; SQ=Soma de Quadrados; P>F=nível de significância exata no teste F, PVE=Porcentagem da Variância Explicada, R^2=coeficiente de determinação; CV=Coeficiente de Variação.

Exp	FV	Zona de manejo 1							Zona de manejo 2					
		GL	SQ	P>F	PVE	R^2	Média	CV	SQ	P>F	PVE	R^2	Média	CV
1	Linha	3	3754079	0,017	75,4		3370	11,8	227941	0,366	9,4		5376	4,5
	Coluna	3	258694	0,670	5,2	81			1752324	0,010	72,3	85		
	NP	3	14398	0,992	0,3				85268	0,711	3,5			
	Resíduo	6	950181	-	19,1	-			358434	-	14,8	-		
	Total	15	4977353	-	-	-			2423967	-	-	-		
2	Linha	3	5715271	0,035	42,5		3604	16,1	313984	0,001	10,0		5538	1,3
	Coluna	3	3955265	0,073	29,4	85			2561602	0,000	81,9	99		
	NP	3	1757559	0,258	13,1				223767	0,003	7,2			
	Resíduo	6	2019735	-	15,0	-			28922	-	0,9	-		
	Total	15	13447830	-	-	-			3128276	-	-	-		
3	Linha	3	63267	0,269	7,8		6297	1,8	9673	0,926	0,5		5722	2,6
	Coluna	3	604620	0,003	74,7	91			1560777	0,001	76,5	94		
	NP	3	66654	0,253	8,2				341007	0,040	16,7			
	Resíduo	6	75368	-	9,3	-			128398	-	6,3	-		
	Total	15	809909	-	-				2039854	-	-	-		
4	Linha	3	400296	0,025	23,4		6598	2,2	109668	0,214	5,2		5747	2,3
	Coluna	3	756325	0,005	44,3	93			1212457	0,001	57,9	95		
	NP	3	431320	0,021	25,2				663285	0,006	31,7			
	Resíduo	6	121002	-	7,1	-			109247	-	5,2	-		
	Total	15	1708943	-	-	-			2094658	-	-	-		

As análises de regressão realizadas sobre os preditores de mínimos quadrados da produtividade, obtidos a partir do modelo de ANOVA, em função do número de plantas, estão apresentadas na FIGURA 6. A relação entre produtividade e população de plantas também foi significativa para os mesmos experimentos observados na ANOVA. Além disso, foi detectada significância para a população de plantas no experimento 3 na ZM1, embora esse fator isoladamente não tenha contribuído de forma significativa para a variação total da produtividade.

Nos experimentos em que a produtividade foi significativamente influenciada pela população de plantas, os coeficientes angulares indicam que, em média, o acréscimo de uma planta por metro nos experimentos 3 e 4, ZM1, resultou em incrementos de 38 kg ha?¹ e 93 kg ha?¹, respectivamente. Na ZM2, os experimentos 2, 3 e 4 mostraram incrementos de 67 kg ha?¹, 84 kg ha?¹ e 113 kg ha?¹ para cada planta adicional por metro.



a Eq. (23)	S_a Eq. (24)	b Eq. (25)	S_b Eq. (26)	$P > F$ Eq. (27)	R^2 Eq. (28)	a Eq. (29)	S_a Eq. (30)	b Eq. (31)	S_b Eq. (32)	$P > F$ Eq. (33)	R^2 Eq. (34)
3300	115	7,1	11,6	0,600	16	5221	283	15,9	28,6	0,634	13
2150	907	149,1	91,7	0,246	57	4882	150	67,2	15,1	0,047	91
5924	30	38,3	3,0	0,006	99	4900	151	84,3	15,3	0,031	94
5686	202	93,5	20,5	0,045	91	4643	306	113,3	30,9	0,067	87

FIGURA 6. Análises de regressão ( ) entre o preditor de mínimos quadrados para a produtividade, em função do número de plantas por hectare. =Intercepto; =erro padrão de ; =coeficiente angular da reta; =erro padrão de ; =nível de significância exata no teste para o modelo; =coeficiente de determinação.

Apesar do número limitado de experimentos em cada zona, estes foram conduzidos em ZM claramente definidas, estabelecendo correlações entre os índices de vegetação adotados e a produtividade. Isso permitiu a extração de informações valiosas que irão orientar futuros trabalhos onde serão empregados experimentos *on-farm*.

CONCLUSÃO

Este trabalho teve como principal objetivo demonstrar a utilidade das ferramentas de sensoriamento remoto e dos dados obtidos por meio desse método para a definição de zonas de manejo (ZM) e para a avaliação da resposta da cultura do algodão à variação na densidade populacional. Foram explorados o uso de índices de vegetação derivados de imagens de sensoriamento remoto com alta resolução espacial e temporal, com o intuito de determinar os momentos mais adequados para realizar análises com base nessas imagens, considerando suas correlações tanto com a taxa de população utilizada quanto com a produtividade final do ciclo. As análises estatísticas **permitiram identificar a variação do potencial produtivo nas diferentes zonas e avaliar a capacidade de resposta de cada zona à variação da densidade populacional. A definição de ZM foi uma estratégia eficaz para o posicionamento dos experimentos *on-farm*, potencializando a observação dos resultados obtidos. A experimentação *on-farm* mostrou-se útil na tomada de decisões sobre a utilização da taxa variável de sementes em talhões com variabilidade espacial dos índices de vegetação. No entanto, não foram observados benefícios significativos na redução da taxa de semeadura. Estudos futuros devem focar no ajuste da taxa de semeadura com base na variabilidade espacial dos índices vegetativos.**

AGRADECIMENTOS

Agradecemos ao grupo Amaggi pelo suporte operacional e disponibilização dos dados coletados e à Robert Bosch Ltda. e Embrapa pelo financiamento desta pesquisa (proc. 10.22.00.001).

REFERÊNCIAS

ABRAPA. **Associação Brasileira dos Produtores de Algodão**. Disponível em: <https://www.abrapa.com.br>. Acesso em: 02 de abril de 2024.

BASSOI, L. H. ; INAMASU, R. Y. ; BERNARDI, A.C.C. ; VAZ, C.M.P. ; SPERANZA, E. A. ; CRUVINEL, P. E. Agricultura de precisão e agricultura digital. **TECCOGS: Revista Digital de Tecnologias Cognitivas**, São Paulo, p. 17 - 36.

BREIMAN, L. Random forests. **Machine Learning**, 45(1), 5-32, 2001.

DOBERMANN, A.; PING, J.L.; ADAMCHUK, V.I.; SIMBAHAN, G.C.; FERGUSON, R.B. Classification of crop yield variability in irrigated production fields. **Agron. J**. 2003, 95, 1105-1120.

DOERGE, T. A. **Management Zones Concepts**. Norcross, 1999.

EARTH ENGINE DATA CATALOG. **Harmonized Sentinel-2 MSI: MultiSpectral Instrument, Level-1C**. Disponível em https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S2_HARMONIZED. Acesso em: 02 de abril de 2024.

HUETE, A.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E. P.; GAO, X.; FERREIRA, L. G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote sensing of environment**, v. 83, n. 1-2, p. 195-213, 2002.

MERZLYAK, M. N. Non?destructive optical detection of pigment changes during leaf senescence and fruit ripening. **Physiologia plantarum**, v. 106, n. 1, p. 135-141, 1999.

MOLIN, J. P.; AMARAL, L.R.; COLAÇO, A. **Agricultura de precisão**. Oficina de Textos, 2015.

MACQUEEN, J. **Some methods for classification and analysis of multivariate observations**. In: Proceedings of the fifth Berkeley symposium on mathematical statistics and probability. 1967. p. 281-297.

MONTGOMERY, D.C. **Design and Analysis of Experiments.** Arisona State University. Ninth Edition, John Wiley & Sons, New York, 640 p, 2017

SIQUEIRA, D.A.B.D.; VAZ, C.M.P.; SILVA, F.S.; FERREIRA, E.J.; SPERANZA, E.A.; FRANCHINI, J.C.; GALBIERI, R.; BELOT, J.L.; SOUZA, M.D.; PERINA, F.J.; CHAGAS, S.D. Regional-Scale Cotton Yield Estimate in the Brazilian Cerrado Using Simple Linear Regression Models with Time-Series of Vegetation Indices from EOS-MODIS Satellite Data. Preprints 2024, 2024021397. https://doi.org/10.20944/preprints202402.1397.v1

SISHODIA, Rajendra P.; RAY, Ram L.; SINGH, Sudhir K. Applications of remote sensing in precision agriculture: A review. **Remote sensing**, v. 12, n. 19, p. 3136, 2020.

SHIRATSUCHI, L.S. et al. On-Farm Precision Experimentation with Cotton to Generate Algorithms for Site-Specific Management of Nitrogen Fertilizers Based on Airborne Imagery. In: **ASA, CSSA and SSSA International Annual Meetings (2019)**. ASA, CSSA, and SSSA, 2019.

APLICABILIDADE DE DADOS ESPACIALIZADOS OBSERVACIONAIS NA CANA-DE-AÇÚCAR

MARCELO CHAN FU WEI [1]; EUDOCIO RAFAEL OTAVIO DA SILVA [1]; RICARDO CANAL FILHO [1]; JOSÉ PAULO MOLIN [2]

[1]Doutorando. Avenida Pádua Dias, 11, 13418-900, Piracicaba, São Paulo, Brasil. Universidade de São Paulo - Escola Superior de Agricultura 'Luiz de Queiroz; [2]Docente. Avenida Pádua Dias, 11, 13418-900, Piracicaba, São Paulo, Brasil. Universidade de São Paulo - Escola Superior de Agricultura 'Luiz de Queiroz

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Com a maior disponibilidade de acesso a dados observacionais da produção agrícola da cana-de-açúcar e a facilidade de aplicar diferentes métricas estatísticas para inferir relações causais, faz-se necessário avaliar se o resultado estatístico indicará as mesmas variáveis relacionadas à produtividade como importantes que àquelas consideradas pela literatura (por exemplo, ciclo de corte, maturação, variedade e ambiente de produção). O objetivo do trabalho foi demonstrar como podem ser utilizados os dados observacionais para auxiliar a gestão agrícola da cana-de-açúcar em termos varietais e de adubação. Para isso, foi realizada a análise de regressão por árvore de decisão e florestas aleatórias em um conjunto de dados com 473 observações e 18 variáveis e comparadas as variáveis que mais influenciaram a produtividade em cada modelo de regressão. Como resultado, identificou-se que variáveis, como a variedade, ciclo de corte, maturação e teor de enxofre no solo, foram importantes para os modelos de regressão. Entretanto, a variável "ambiente de produção", que é considerada uma das principais utilizadas no manejo da cultura, não foi indicada como importante para os modelos de regressão. Este trabalho demonstra que é possível utilizar os dados observacionais para auxiliar a tomada de decisão, entretanto é necessária cautela para a sua interpretação, uma vez que a importância de cada variável depende do modelo de regressão aplicado e podem ser distintos do que é considerado pela literatura.

PALAVRAS-CHAVE: análise de dados; árvore de decisão; florestas aleatórias

ABSTRACT

Having more access to observational data from sugarcane agricultural production and the ease of applying different statistical algorithms for causal inference, underpin the need to evaluate whether the results of data analysis will indicate the same variables as important to yield as those considered in the literature (e.g., cutting cycle, maturation, variety and production environment). The objective of this work was to demonstrate how observational data can be used to assist the agricultural management of sugarcane related to variety selection and fertilizer application. To this end, regression analysis was performed on a database composed of 473 observations and 18 variables using decision tree and random forest regressions and the variables that most influenced yield in each regression model were compared. As a result, it was identified that some variables such as variety, cutting cycle, maturation and sulfur content were considered important for both models. However, the variable "production environment", which is considered one of the main variables used in sugarcane crop management, was not indicated as important for the models. This work demonstrates the feasibility to use observational data to assist decision-making, however the interpretation must be assessed carefully since variable importance depends on the regression model applied and they might vary from the literature.

KEYWORDS: ;

INTRODUÇÃO

A maior disponibilidade de dados diretamente ou indiretamente relacionados à produção de uma cultura agrícola, tais como dados do solo, da planta e/ou atmosfera, tornam as análises de dados mais complexas. Métodos de aprendizado de máquina para predição estão sendo utilizados amplamente em diversas áreas, entretanto ressalta-se a limitação deles na questão de estabelecer corretamente relações causais (YOUNAS et al., 2022). A identificação de relações causais é fundamental para estabelecer e melhorar as tomadas de decisões minimizando os riscos, contudo é necessário conduzir diversos estudos, que requerem tempo, dinheiro e capacidade técnica para avaliar (BRAND et al., 2021). Como alternativa, pode-se recorrer ao uso de dados históricos ou dados observacionais (características de interesse observadas ao longo de um período sem intervenção do investigador), uma vez que a análise deles pode indicar relações causais (SCHAPIRE, 1990). A inferência causal em dados observacionais já é relatada em diversas áreas de estudos, principalmente relacionadas à ecologia aplicada e medicina, uma vez que o estabelecimento de tratamentos a serem comparados é um fator limitante. Na agricultura, a depender da cultura, as variáveis apresentam maior expressão/representatividade em relação à produtividade do que outras. Por exemplo, na cultura do milho, a textura do solo é uma característica/variável que auxilia o dimensionamento populacional, sendo que a população (densidade de sementes por ha) está relacionada à produtividade final da cultura (ANSELMI et al., 2021). Já na cana-de-açúcar, variáveis como ciclo de corte (MARIN et al., 2019), maturação, variedade (CRUZ e MACHADO, 2023) e ambiente de produção (BARBOSA et al., 2021) são alguns dos fatores mais importantes a serem considerados na sua gestão. Logo, ciente da disponibilidade de dados observacionais e da capacidade de algoritmos identificarem relações causais sem o conhecimento prévio, torna-se oportuno explorar se as variáveis que são consolidadas como importantes durante a tomada de decisão da gestão agrícola são as mesmas identificadas em modelos de predição relacionadas à produtividade de cana-de-açúcar. A hipótese desse trabalho é que as variáveis indicadas como mais importantes a partir dos dados observacionais não serão as mesmas indicadas pela literatura e/ou usuários (como por exemplo, ciclo de corte, maturação, variedade e ambiente de produção), uma vez que algoritmos são capazes de realizar associações entre variáveis sem nexo causal conhecido.

OBJETIVOS

O objetivo deste trabalho foi demonstrar conceitualmente como podem ser utilizados dados observacionais espacializados (planta e solo) para auxiliar a gestão agrícola da cana-de-açúcar em termos varietais e de adubação, enfatizando a necessidade da contextualização para uma correta interpretação.

MATERIAL E MÉTODOS

O trabalho foi realizado utilizando um conjunto de dados observacionais de 2022 obtidos de um grupo empresarial do setor sucroenergético brasileiro localizado na região Sudeste do Brasil. O conjunto de dados é composto por 473 observações e 18 variáveis, sendo elas: variedade, estágio/ciclo de corte, maturação, ambiente de produção, produtividade estimada (esperada) pela usina, produtividade colhida (observada) e resultados de análise química do solo de amostras coletadas na profundidade de 0 - 0,20 m (potencial de hidrogênio com base no cloreto de cálcio pH $CaCl_2$, potencial de hidrogênio pelo método de Shoemaker, Mac Iean e Pratt -pH-SMP, teor de fósforo - P, teor de potássio - K, teor de cálcio - Ca, teor de magnésio - Mg, teor de alumínio - Al, teor de enxofre - S, acidez potencial - soma dos teores de hidrogênio e alumínio (H + Al), soma de bases - SB, capacidade de troca catiônica - CTC, saturação por bases - V%, matéria orgânica do solo - MOS).

Os dados foram analisados a partir da sua análise descritiva (valores máximos, mínimos, médio, mediana, primeiro e terceiro quartil). Os dados de produtividade esperada e observada foram comparados usando o *boxplot* divididos por estágio de corte e variedade com o intuito de observar a

diferença entre eles, reforçando a necessidade de utilizar dados que representem o resultado mais próximo do real, uma vez que eles podem interferir em tomadas de decisões baseadas em produtividade, como a recomendação de adubação.

Em seguida, foram aplicados dois modelos de regressão: (a) árvore de decisão e (b) árvores aleatórias com o intuito de observar as variáveis de maior importância para cada modelo (árvore de decisão foi observado pela árvore criada e florestas aleatórias pelos índices de acurácia média perdida e de Gini) e comparar àquelas consideradas mais importantes na gestão da cana-de-açúcar. O índice de acurácia média perdida indica o quanto de acurácia o modelo ajustado perde ao excluir uma determinada variável e o índice de Gini mensura o quanto cada variável contribui para a homogeneidade da estrutura da árvore (nós e folhas) de regressão. De forma geral, a sua interpretação pode ser feita considerando que quanto maior o valor do índice de acurácia média perdida e/ou índice de Gini, maior a importância de determinada variável para a regressão ajustada (JANITZA et al. 2016).

Para a ajuste dos modelos de regressão, foram consideradas a produtividade observada como variável dependente (Y) e os resultados das análises de solo, variedade, estágio de corte, maturação e ambiente de produção como variáveis independentes (X). A árvore de decisão e a regressão por árvores aleatórias foram otimizadas aplicando o método da regra do cotovelo (TRACY et al., 2016) (Figura 1). A análise dos dados foi realizada no programa RStudio (R CORE TEAM, 2018).

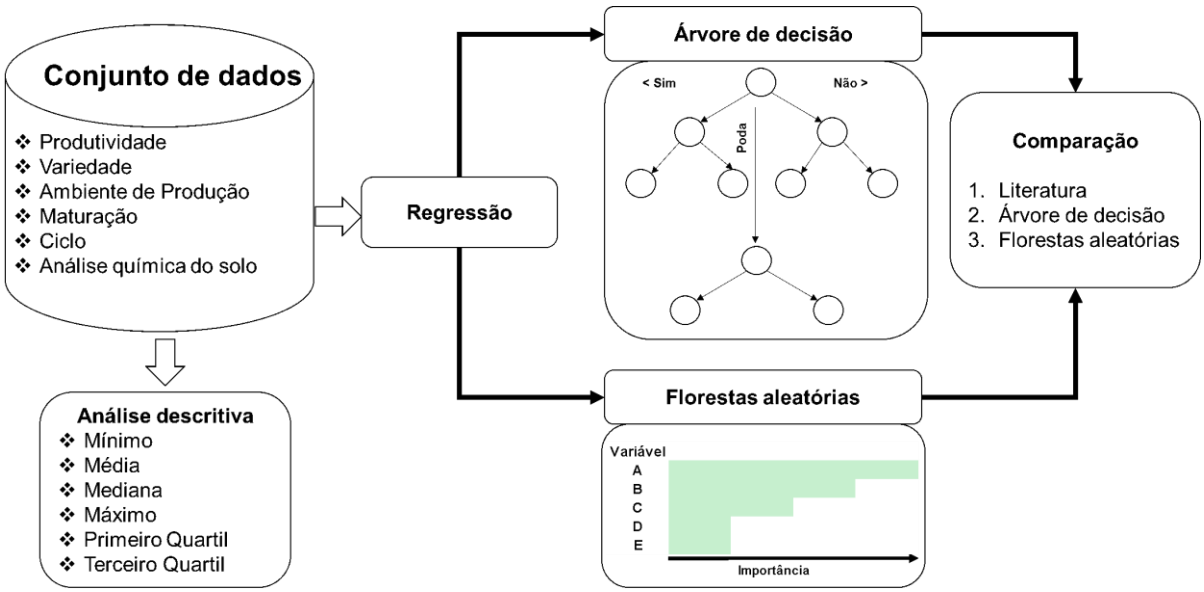


FIGURA 1. Fluxograma da análise de dados da cana-de-açúcar.

RESULTADOS E DISCUSSÃO

A partir da Tabela 1, nota-se que existe uma variabilidade acentuada em todas as variáveis observadas, incluindo o teor de Al, apesar deste atributo ser mais expressivo em camadas de profundidade de solo superiores aos 0,20 m. Observando os valores de pH $CaCl_2$ (4,51 - 7,31), pode-se identificar que o cultivo está sendo realizado em áreas de pH ácido até neutro, o que pode impactar diretamente na produtividade da cultura da cana-de-açúcar, caso a variedade escolhida não tenha sido selecionada corretamente para a região e/ou a calagem tenha sido realizada de forma incorreta. Outra variável importante relacionada ao pH é a V (%), em que observa-se que existem regiões com valores mínimos de 11% e outras com máximos de 94%, sendo que o indicado como ideal para o cultivo da cana-de-açúcar na região Centro-Sul brasileiro é elevar para no mínimo 70% (QUAGGIO et al., 2022), logo identificando que a maior parte dos pontos amostrais já estão com a V (%) próxima desse valor (primeiro quartil - 69%). Em relação à adubação com base nos resultados dos demais nutrientes, esta é dependente da produtividade esperada, como observado no BOLETIM 100 (QUAGGIO et al.,

2022), uma vez que apresenta relação com a quantidade de nutrientes exportados pela cana-de-açúcar após a sua colheita, conceito adaptado de STANFORD (1973).

TABELA 1. Análise descritiva dos dados de solo e produtividade da cana-de-açúcar.

n = 473	MOS	pH-SMP	pH $CaCl_2$	P resina	S	K	Ca	Mg	Al	H+Al	SB	CTC	V	Prod Observada
Valor	g dm^{-3}		-	mg dm^{-3}				$mmol_c$ dm^{-3}					%	t ha^{-1}
Mínimo	11,91	4,29	4,51	2,12	1,36	0,73	6,94	2,76	0,00	5,97	11,90	23,44	11,62	18,11
Primeiro Quartil	18,68	7,17	5,38	7,47	4,43	1,97	14,83	8,00	0,41	9,48	26,41	38,49	69,49	70,76
Mediana	21,22	7,28	5,84	12,02	6,40	3,25	22,00	11,02	0,41	10,99	37,42	48,45	77,64	90,05
Média	21,82	7,28	5,86	14,66	7,10	3,71	24,54	13,39	0,47	11,81	41,64	53,45	75,85	95,97
Terceiro Quartil	24,60	7,42	6,27	21,11	8,45	4,73	31,29	16,67	0,41	12,34	51,14	63,43	83,26	123,34
Máximo	44,88	7,86	7,31	48,88	38,91	14,53	87,35	58,76	9,40	256,01	127,28	289,68	94,29	207,59

Al = alumínio, Ca = cálcio, CTC = capacidade de troca catiônica, H+Al = acidez potencial, K = potássio, Mg = magnésio, MOS = matéria orgânica do solo, n = número de amostras, P = fósforo, pH $CaCl_2$ = potencial de hidrogênio com base no cloreto de cálcio, pH-SMP = potencial de hidrogênio pelo método de Shoemaker, Mac Iean e Pratt - SMP, Prod = produtividade, S = enxofre, SB = soma de bases, V = saturação por bases e Prod Observada = Produtividade Observada.

Sabendo que a recomendação de adubação é baseada na produtividade esperada, torna-se evidente e esperado que seja utilizada a camada de dados de produtividade colhida em campo. Entretanto, é notório que ainda existe uma dificuldade em utilizar essa camada de dados devido à uma série de fatores (por exemplo, necessidade de calibração constante, limpeza do sistema sensor, filtragem dos dados, entre outros) relacionadas ao sistema de monitoramento de produtividade (FULTON et al., 2018). A partir da Figura 2, observa-se que os valores de produtividade apresentaram diferenças entre observado e estimado pela usina, considerando ciclos de corte e variedades. Isso pode ter ocorrido devido à complexidade da interação de fatores com a produtividade, uma vez que as recomendações de fertilizantes são baseadas em produtividade esperada oriunda do cálculo empírico e não do resultado em campo, o que é considerado como falho (RODRIGUEZ et al., 2019). As recomendações das usinas geralmente são baseadas em valores médios, desconsiderando a especificidade local, tornando a adubação ineficiente e os resultados de produtividade esperados distintos dos colhidos.

Logo, esses resultados reforçam a necessidade do uso da camada de dados da produtividade efetivamente colhida como camada referência para recomendação futura de adubação, uma vez que ela reflete os valores mais recentes obtidos, podendo maximizar a eficiência do uso de fertilizantes e corretivos, corroborando com o tripé (econômico-ambiental-social) do desenvolvimento sustentável (CICCIU et al., 2022).

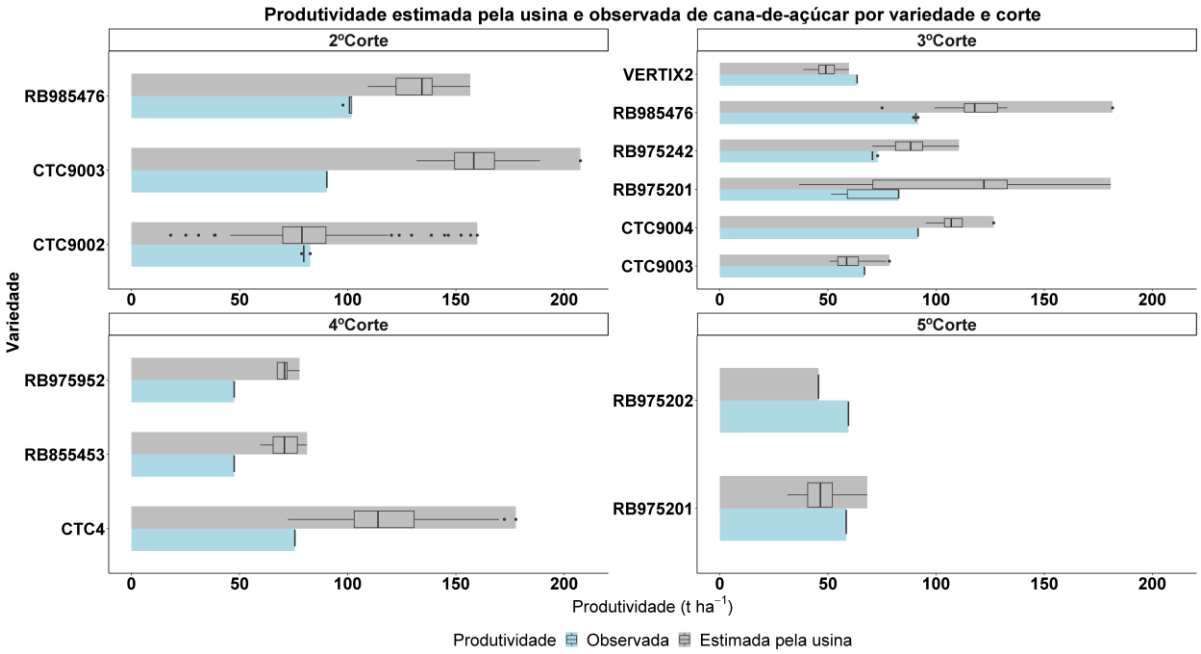


FIGURA 2. Boxplot dos valores de produtividade estimados pela usina e observados de diferentes variedades e ciclos de corte da cana-de-açúcar. 2º = segundo, 3º = terceiro, 4º = quarto e 5º = quinto.

A árvore de decisão utilizando a variável de produtividade como resposta indica que as variáveis "variedade", "estágio", "maturação" e teor de S são as que mais influenciaram no desenvolvimento da árvore. Esses resultados indicam que variáveis como "Ambiente de produção", "pH" e "V (%)" não foram importantes para a componente de produtividade (Figura 3). Entretanto, atenção ao interpretar os dados é necessária, uma vez que a árvore de decisão é uma regressão que pode ser utilizada em análises de inferência causal (YOUNAS et al., 2022), mas os seus resultados não necessariamente expressam nexo causal. Apesar disso, o seu uso é importante uma vez que pode auxiliar a tomada de decisão dos gestores. Contudo ressalta-se a importância do acompanhamento de especialistas na área agronômica para aferir a confiabilidade dos resultados.

A partir da Figura 3, observa-se que para as variedades CTC 9002, RB855453, RB975201, RB975202, RB975242, RB975952 e VERTIX 2, caso estejam no quinto corte, a sua produtividade média foi menor que 50 t ha^{-1}. A partir desse segmento da árvore de decisão, é possível auxiliar o gestor de produção de cana-de-açúcar em relação à reforma do canavial, uma vez que com essa produtividade média obtida pode inviabilizar a produção do próximo ciclo em termos econômicos, o que corrobora com estudos que indicam que quanto maior o ciclo da cultura, menor é a sua produtividade (SILVA et al., 2018). Entretanto, outros cenários também podem ser analisados, como por exemplo, ao selecionar a produtividade média de 61 t ha^{-1}, identifica-se que áreas cultivadas com variedade CTC9003 e que estão em seu terceiro ou quarto corte, apresentam baixas produtividades, podendo indicar um alerta ao gestor quanto às essas áreas para possíveis intervenções.

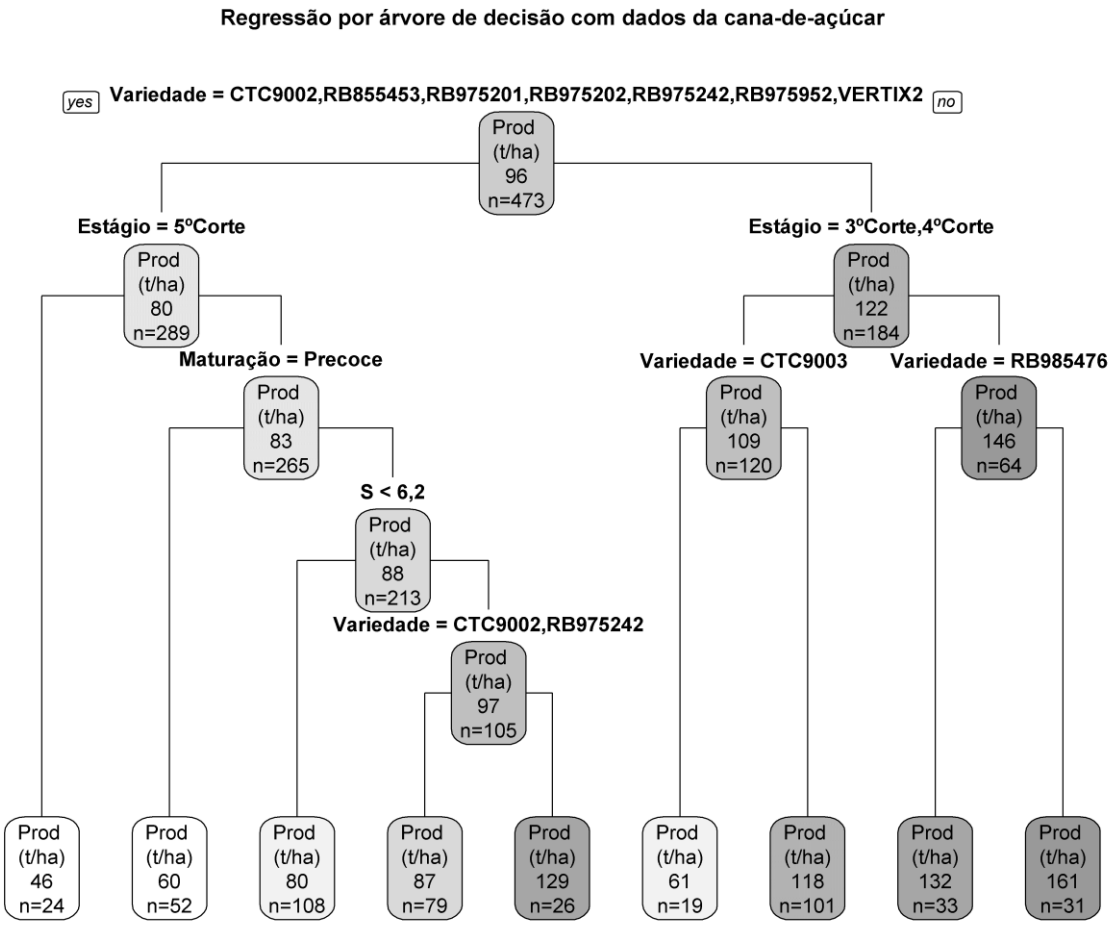


FIGURA 3. Árvore de decisão obtida considerando o valor de produtividade de cana-de-açúcar como variável resposta. 3º: terceiro, 4º: quarto, 5º quinto, n = número de amostras, no = não, prod = produtividade, S = teor de enxofre e yes =sim.

Da Figura 4, observa-se que cada nível dentro de variedade, ciclo, maturação e ambiente de produção apresentam graus de importância distintos, sendo que quanto maior a acurácia média perdida/índice de Gini, maior a importância da variável na regressão. Esse resultado é importante porque pode auxiliar a identificar variáveis com especificidade local e possibilitar a customização de recomendações. Em relação às variáveis que apresentaram maior importância na regressão por árvores aleatórias, dentre as dez mais importantes pelo índice de acurácia média perdida (%) tem-se: Variedade RB985476 > Estágio 5º Corte > pH > Maturação Precoce > teor de S > Variedade CTC4 > Estágio 2º Corte > Variedade VERTIX 2 > P resina > acidez potencial. Já em relação a acurácia medida pelo índice de Gini, tem-se: pH > Variedade RB985476 > acidez potencial > V (%) > Estágio 5º corte > teor de enxofre > P resina > Maturação Precoce > teor de Mg > Estágio 2º corte (Figura 4).

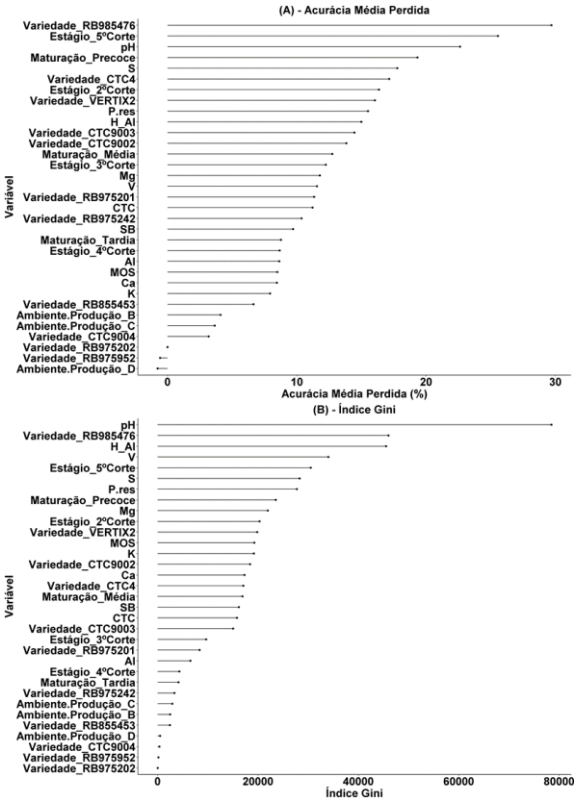


FIGURA 4. Importância das variáveis pela regressão por árvores aleatórias com base nos índices de (A) acurácia média perdida e (B) Gini. 2º = segundo, 3º = terceiro, 4º = quarto, 5º = quinto, Al = alumínio, Ca = cálcio, CTC = capacidade de troca catiônica, H_Al = acidez potencial, K = potássio, Mg = magnésio, MOS = matéria orgânica do solo, pH = potencial de hidrogênio com base no cloreto de cálcio, P.res = fósforo resina, S = enxofre e SB = soma de bases.

Note que, de forma geral, algumas variáveis foram utilizadas por ambas regressões como "Maturação", "Variedade", "Estágio" e teor de "S" e ambas foram pouco influenciadas pela variável "Ambiente de Produção". É indiscutível que a variável variedade é importante para a produtividade da cana-de-açúcar, sendo observado em ambos modelos (Figuras 3 e 4), além de ser indicado em outros estudos (SANCHES e OTTO, 2022; CRUZ e MACHADO, 2023), mesmo avaliando variedades diferentes das estudadas nesse trabalho. Esses resultados corroboram com a hipótese do trabalho na qual esperava-se que as variáveis estudadas como variedade, ciclo de corte, maturação e ambiente de produção não apresentassem a mesma importância encontrada pela literatura, sendo que neste caso, o ambiente de produção foi a variável considerada não relevante nos modelos de regressão.

Em relação às demais variáveis, principalmente aquelas relacionadas aos atributos químicos do solo, a sua interpretação é mais complexa, uma vez que a interação também depende de fatores como atributos físicos do solo, que neste caso, não foram utilizados na análise. Entretanto, a variável de classificação do solo quanto ao ambiente de produção foi utilizada, e sabe-se que ela é classificada considerando a classe textural do solo, CTC, além de outras variáveis (PRADO, 2008). Dessa forma, ressalta-se a necessidade de cautela na interpretação dos resultados estatísticos sem o conhecimento agronômico porque poderia indicar que o ambiente de produção é uma variável desnecessária a ser considerada na produção da cana-de-açúcar.

Sabendo que existem evidências de que é necessário o maior entendimento das interações entre variáveis para melhorar o entendimento de suas relações, a análise de dados observacionais de forma espacializada pode ser uma alternativa para auxiliar a identificação de possíveis relações importantes entre elas (SCHAPIRE, 1990), que posteriormente devem ser avaliadas com rigor científico, agronômico e estatístico.

Diante do apresentado, outras questões a serem respondidas emergem como: (a) "Essas variáveis apresentam relações causais com a produtividade de cana-de-açúcar?" e (b) "Como eu posso avaliar se essas variáveis apresentam essas relações de causa-efeito?". Caso essas variáveis apresentem relações causais com a produtividade da cana-de-açúcar, fica evidente que a estimativa de produtividade com base em fatores que podem ser alterados pelo ser humano, como adubação e manejo varietal, tornar-se-á mais acurada e precisa. Nota-se que esforços vêm sendo desenvolvidos com o intuito de melhorar a gestão agrícola da cana-de-açúcar, sobretudo relacionado à adubação, como observado em BRAMLEY et al. (2017) e SANCHES e OTTO (2022), entretanto dúvidas sobre as relações causais entre as variáveis estudadas e a produtividade ainda permeiam sobre o limiar do conhecimento científico.

Ciente do avanço da aplicação de diversas técnicas de análise de dados, popularmente associados à inteligência artificial e aprendizado de máquina, e uma atração de pessoas de setores distintos do conhecimento para o setor agrícola, esse trabalho mostra que, conceitualmente, resultados diferentes são esperados a partir da aplicação de métodos de regressão, sendo que não existe um consenso entre o melhor método. Entretanto, a sua interpretação depende da contextualização e do conhecimento específico do gestor sobre determinado conjunto de dados. Logo, é evidenciada a necessidade de ter cautela ao realizar análise de dados sem um prévio conhecimento das variáveis do conjunto de dados.

A partir desses resultados, pode-se inferir que o uso de dados observacionais, a depender da técnica utilizada, pode gerar interpretações distintas. Nesse trabalho, observa-se que as variáveis com maior importância foram distintas entre os modelos aplicados, apesar de apresentarem algumas variáveis similares entre eles. Investigações aprofundadas com os gestores são necessárias para identificar se as variáveis classificadas como mais importantes apresentam nexo causal com a produtividade. Além disso, para melhorar a interpretação dos dados observacionais, é necessário adicionar mais camadas de dados como os dados agrometeorológicos e os dados de aplicação de insumos.

Dessa forma, mostra-se a importância do uso dos dados observacionais espacializados em relação à gestão da cultura da cana-de-açúcar. Apesar de ser constituído por apenas uma única safra, esse conjunto de dados e análise pode auxiliar na recomendação de fertilizantes dos próximos ciclos, uma vez que ela contém dados fundamentais para a recomendação, como produtividade observada (camada de dados mais fidedigna do que a camada de dados de produtividade estimada pela usina - método empírico), saturação por bases e teor de nutrientes no solo. Não obstante, reitera-se que este trabalho representa uma abordagem conceitual sobre como poderia ser realizada a análise de um conjunto de dados observacionais na agricultura.

CONCLUSÃO

Os resultados desse trabalho mostram que as variáveis mais importantes relacionadas à produtividade da cana-de-açúcar dependem do modelo de regressão utilizado, sendo que, de forma geral, foram considerados importantes: variedade, ciclo de corte e maturação e não importante: ambiente de produção. Dados observacionais devem ser utilizados com cautela porque o sistema agrícola é complexo e provavelmente as variáveis utilizadas não necessariamente apresentam nexo causal; além disso, o conjunto de dados pode estar incompleto.

AGRADECIMENTOS

À Solinftec pelo suporte na obtenção dos dados.

REFERÊNCIAS

ANSELMI, A. A.; MOLIN, J. P.; BAZAME, H. C.; CORREDO, L. P. Definition of Optimal Maize Seeding Rates Based on the Potential Yield of Management Zones. **Agriculture**, v. 11, 2021.

BARBOSA, A. de M.; ZILLIANI, R. B.; TIRITAN, C. S.; SOUZA, G. M.; SILVA, M. A. Energy conversion efficiency in sugarcane cultivars as a function of production environments in Brazil. **Renewable and Sustainable Energy Reviews**, v. 150, 2021.

BRAMLEY, R. G. V.; OUZMAN, J.; GOBBETT, D. L. Yield mapping at different scales to improve fertilizer decision making in the Australian sugar industry. **Advances in Animal Biosciencies**, v. 8, 2017.

BRAND, J. E.; XU, J.; KOCH, B.; GERALDO, P. Uncovering Sociological Effect Heterogeneity Using Tree-Based Machine Learning. **Sociological Methodology**, v. 51, p. 189 - 223, 2021.

CICCIU, B.; SCHRAMM, F.; SCHARAMM, V. B. Multi-criteria decision making/aid methods for assessing agricultural sustainability: A literature review. **Environmental Science & Policy**, v. 138, p. 85-96, 2022.

CRUZ, T. V.; MACHADO, R. L. Measuring climate change's impact on different sugarcane varieties production in the South of Goiás. **Scientific Reports**, v. 13, 2023.

FULTON, J.; HAWKINS, E.; TAYLOR, R.; FRANZEN, A. Yield monitoring and mapping. *In*: SHANNON, Kent; CLAY, David E.; KITCHEN, Newell R. **Precision Agriculture Basics**, 2018.

JANITZA, S.; TUTZ, G.; BOULESTEIX, A. Random forest for ordinal responses: prediction and variable selection. **Computational Statistics & Data Analysis**, v. 96, p. 57 - 73, 2016.

MARIN, F. R.; EDREIRA, J. I. R.;ANDRADE, J.; GRASSINI, P. On-farm sugarcane yield and yield components as influenced by number of harvests. **Field Crops Research**, v. 240, p. 134 - 142, 2019.

PRADO, H. Pedologia fácil aplicações na agricultura. 2. ed. Piracicaba: 2008. 145p

QUAGGIO, J. A.; CANTARELLA, H.; VAN RAIJ, B.; OTTO, R.; PENATTI, C. P.; VITTI, G. C.; KORNDORFER, G. H.; TRIVELIN, P. C. O.; MELLIS, E. V.; FRANCO, H. C. J.; GAVA, G. J. C.; VITTI, A. C.; DIAS, F. L. Cana-de-açúcar. *In*: CANTARELLA, Heitor; QUAGGIO, José Antonio; MATTOS Jr, Dirceu, BOARETTO, Rodrigo Marcelli, VAN RAIJ, Bernardo (Eds.). **Boletim 100: recomendações de adubação e calagem para o estado de São Paulo**, 2022.

RODRIGUES, D. G. P.; BULLOCK, D. S.; BOERNGEN, M. A. The origins, implications, and consequences of yield-based nitrogen fertilizer management. **Agronomy Journal**, v. 111, p. 725-735, 2019.

SANCHES, G. M.; OTTO, R. A novel approach for determining nitrogen requirement based on a new agronomic principle-sugarcane as a crop model. **Plant and Soil**, v. 472, p. 29-43, 2022.

SILVA, V. S. G.; OLIVEIRA, M. W.; FERREIRA, V. M.; OLIVEIRA, T. B. A.; SANTANA, M. B.; GALVÃO, E. R. Produção de colmos e acumulação de nutrientes por variedades de cana-de-açúcar em três ciclos de colheita. **Revista de Ciência Agrárias**, v. 41, p. 415-423, 2018.

R CORE TEAM. R: A Language and Environment for Statistical Computing; R Foundation for Statistical Computing: Vienna, Austria, 2018.

STANFORD, G. 1973. Rationale for optimum nitrogen fertilization in corn production. **Journal of Environmental Quality**, 1973.

TRACY, T.; FU, Y.; ROY, I.; JONAS, E.; GLENDENNING, P. Towards Machine Learning on the Automata Processor. *In:* KUNKEL, Julian, BALAJI, Pavan, DONGARRA, Jack. (Eds.). **High Performance Computing, 2016.**

YOUNAS, N.; ALI, A.; HINA, H.; HAMRAZ, M.; KHAN, Z.; ALDAHMANI, S. Optimal causal decision trees ensemble for improved prediction and causal inference. **Institute of Electrical and Electronics Engineers - IEEE**, v. 10, p. 13000-13011, 2022.

REVISITANDO O TEMA DOS ERROS EM DADOS OBTIDOS POR MONITORES DE PRODUTIVIDADE DE MILHO E SOJA

LUIZ GUSTAVO DE GÓES STERLE [1]; MARCELO CAMPONEZ DO BRASIL CARDINALI [1,3]; LEONARDO VEDOVATO GIMENEZ [1]; VINICIUS CAMPANA BENASSI [1]; JOSÉ PAULO MOLIN [2]

[1]Bolsista. Av. Pádua Dias, 11 - Agronomia, Piracicaba - SP, 13418-900. Escola Superior de Agricultura 'Luiz de Queiroz; [2]Docente. Av. Pádua Dias, 11 - Agronomia, Piracicaba - SP, 13418-900. Escola Superior de Agricultura 'Luiz de Queiroz; [3]Docente. Av. Pádua Dias, 11 - Agronomia, Piracicaba - SP, 13418-900. Instituto Federal de Educação, Ciência e Tecnologia de São Paulo, IFSP - Câmpus Piracicaba

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Uma das ferramentas mais difundidas na agricultura de precisão são os mapas de produtividade. Considerados essenciais para a gestão agrícola espacializada, sua disseminação enfrenta vários desafios. Dentre estes, a obtenção dos dados requer um processo de pré-processamento para remover erros. O objetivo deste estudo consiste em analisar, quantificar e caracterizar dados errôneos presentes em conjuntos atuais de dados provenientes de lavouras comerciais e abordar aspectos de evolução da qualidade dos dados, avaliando simultaneamente dois métodos de filtragem, estatística e MapFilter 2.0. Na filtragem estatística, realizou-se uma análise exploratória dos dados. A partir dos quartis superior e inferior, foram estabelecidos os limites para a filtragem dos valores de produtividade. Comparativamente, utilizou-se o software MapFilter 2.0, que permite realizar a filtragem estatística e posteriormente a filtragem localizada, por meio da avaliação comparativa de valores de pontos vizinhos. O processo de filtragem estatística removeu entre 1,8 e 14,9%, o software Mapfilter entre 6,8 e 38,9% de dados errôneos e discrepantes. Apesar de ocorrerem em menor frequência nos dados de produtividade atuais, alguns erros persistem, principalmente relacionado aos valores decorrentes de leituras de produtividade nula, indicando que a etapa de filtragem de dados segue sendo fundamental para a obtenção de mapas de produtividade confiáveis.

PALAVRAS-CHAVE: Mapas de Produtividade; Sensores; Filtragem de dados

ABSTRACT

Yield mapping is one of the most widely used tools in precision agriculture and is essential for spatial agricultural management. However, its dissemination faces several challenges, particularly in data acquisition, which requires preprocessing to remove errors. This study aims to analyze, quantify, and characterize erroneous data in current datasets from commercial crops and to address the evolution of data quality by evaluating two filtering methods: statistical filtering and MapFilter 2.0. For statistical filtering, exploratory data analysis was conducted, and upper and lower quartiles were used to set limits for filtering yield values. The MapFilter 2.0 software was also used, which allows for statistical filtering followed by localized filtering through comparative evaluation of neighboring point values. The statistical filtering process removed between 1.8% and 14.9% of erroneous and discrepant data, while the MapFilter software removed between 6.8% and 38.9%. Although errors occur less frequently in current productivity data, some persist, especially those related to zero yield readings, indicating that data filtering remains essential for obtaining reliable yield maps.

KEYWORDS: ;

INTRODUÇÃO

Os monitores de produtividade em colhedoras de grãos foram introduzidos há mais de três décadas, mas sua adoção na agricultura brasileira tem pouco mais de duas décadas. A disseminação dos mapas de produtividade, considerados essenciais para a gestão agrícola espacializada, enfrenta vários desafios, principalmente no que diz respeito à confiabilidade dos dados. Esses monitores combinam dados de sensores, como posicionamento por sistemas globais de navegação por satélite (GNSS), velocidade da colhedora, largura da plataforma, fluxo de grãos e umidade, para calcular a produtividade. A precisão desses sistemas comerciais continua a evoluir e a variedade de opções disponíveis está aumentando (FULTON et al. 2018). Os dados do monitor de produtividade contêm erros de medição associados ao próprio processo de mapeamento da produtividade (PING e DOBERMANN, 2005). Menegatti e Molin (2003) apontaram que o erro de produtividade e umidade nula, à época, era decorrente da falha na leitura pelos sensores e com isso tem-se pontos com valores nulos. O erro da distância nula ocorre quando a distância entre os pontos coletados pelo GNSS é nula. Este erro pode ser decorrente da alta taxa de coleta de pontos associada a pequenos erros de posicionamento do GNSS. Outro erro que pode estar presente nos dados coletados é o erro da largura de corte, decorrente da divergência entre o valor da largura informada no monitor de colheita e a largura parcial efetiva na plataforma de corte. A obtenção dos dados requer um processo de pré-processamento para remover erros (BLACKMORE e MARSHALL, 1996; STAFFORD et al., 1996; LARK et al., 1997; MOORE, 1998; BLACKMORE e MOORE, 1999; THYLÉN et al., 2000; ARSLAN e COLVIN, 2002b). Diferentes sistemas de filtragem de dados têm sido utilizados para melhorar a qualidade da informação obtida pelos mapas. Gimenez e Molin (2004) propuseram uma metodologia para remoção de erros na largura de corte na plataforma, ao avaliar valores médios de pontos coletados, e compará-los com a distância ao ponto imediatamente anterior. Simbahan et al. (2004) analisaram os dados do monitor de produtividade para eliminar erros comuns, aplicando um algoritmo de filtragem sequencial, que rastreia e exclui seis tipos de valores errôneos. Zanella et al. (2018) realizaram a remoção de erros em três etapas principais: primeiro a remoção de dados fora da realidade utilizando limiares superiores e inferiores de produtividade, na segunda etapa a remoção de dados discrepantes globais estabelecendo limiares baseados na estatística descritiva, utilizando o desvio padrão e por fim considerando os pontos vizinhos em um determinado raio. Programas desenvolvidos para essa finalidade são ferramentas utilizadas, a exemplo de Maldaner et al. (2021), que construíram um aplicativo-algoritmo denominado MapFilter 2.0 com a metodologia de remoção de outliers espaciais. Portanto, existem métodos baseados em estatística, em distância, em densidade e em clusters (SMITI, 2020).

OBJETIVOS

O objetivo deste estudo consiste em analisar, quantificar e caracterizar dados errôneos presentes em conjuntos atuais de dados provenientes de lavouras comerciais e abordar aspectos de evolução da qualidade dos dados. Simultaneamente, são avaliados e comparados a filtragem estatística e utilizando o MapFilter 2.0, como estratégia para lidar com esses erros.

MATERIAL E MÉTODOS

Caracterização dos dados

Foram obtidos dados de produtividade de 12 lavouras de milho e soja, provenientes de colhedoras comerciais amplamente utilizadas no Brasil (TAB. 1). Sete conjuntos de dados são de produtividade da cultura do milho e cinco da cultura da soja. Como as áreas não foram completamente mapeadas, a área efetivamente colhida foi obtida multiplicando-se a distância percorrida, pela largura de corte da colhedora. As áreas colhidas possuem entre 27,4 e 226,4 ha, oriundos de propriedades dos estados do Paraná, Mato Grosso e Piauí, entre os anos de 2013 e 2016. A densidade de coleta de dados variou de 398 a 648 pontos ha^{-1}, dependendo da configuração da frequência de coleta do monitor de produtividade e da largura de corte. Em média, a densidade de pontos foi superior na cultura de soja

(ID 8 a 12) em comparação com a cultura de milho (ID 1 a 7), devido à maior frequência de coleta dos dados em algumas colhedoras de soja, nos casos analisados neste trabalho. Também são apresentados os dados das máquinas, com informações referentes à largura de corte nominal (plataforma) e frequência de coleta de dados.

TABELA 1. Informações gerais das máquinas e dos dados obtidos nos 12 talhões.

ID	Estado	Ano de colheita	Cultura	Var.	N° de Pontos	Área Colhida (ha)	Densidade de Pontos (ha)	Máquina	Largura de Corte (Plataforma)	Frequência de coleta (Hz)
1	MT	2016	Milho	MG 652	81224	168.5	482,0	JD	7,5	1
2	MT	2016	Milho	MG 652	21765	46.2	471,1	JD	7,5	1
3	MT	2016	Milho	MG 652	29406	58.6	501,8	JD	7,5	1
4	MT	2015	Milho	6030	81476	150,9	539,9	JD	7,5	1
5	MT	2016	Milho	MG 652	72710	145,6	499,4	JD	7,5	1
6	MT	2016	Milho	MG 652	56687	123,1	460,5	JD	7,5	1
7	MT	2016	Milho	MG 652	106035	226,4	468,4	JD	7,5	1
8	MT	2013	Soja	-	64852	124,7	520,1	CASE	11,8	0,2
9	MT	2013	Soja	-	16050	27,4	585,8	CASE	11,8	1
10	PI	2016	Soja	19342	31485	79,1	398,0	JD	10,25	1
11	MT	2014	Soja	-	106641	222,2	479,9	CASE	10,65	0,33
12	PR	2015	Soja	-	35145	54,2	648,4	CASE	9,14	0,2

Os dados foram exportados da plataforma Operations Center (John Deere), em formato shapefile, para serem trabalhados em ambiente SIG, com o software QGIS, versão 3.22.9 Bialowieza (QGIS, 2023). Os arquivos não continham a coluna de informação das coordenadas, as quais foram inseridas utilizando o complemento Lat Lon Tools versão 3.6.12 (HAMILTON, 2023), utilizando o sistema de projeção de coordenadas métricas, UTM, e os fusos das respectivas propriedades. A camada vetorial de pontos foi exportada no formato CSV para análise exploratória dos dados, classificação dos tipos de erro e realização das filtragens estatísticas. Foi desenvolvido um script em linguagem Python para realização da análise exploratória, classificação dos tipos de erro, pré-filtragem e filtragem estatística.

Pré-filtragem

Na pré-filtragem dos pontos coletados de cada talhão, foram identificadas as frequências de erros de produtividade nula (PN), umidade nula (UN) e distância nula (DN). Os erros de largura de corte (LC) não puderam ser contabilizados devido à ausência de dados. Foram eliminados todos os pontos nessas condições por meio da filtragem estatística. A distância (D)entre dois pontos consecutivos foi obtida por

$$D = \sqrt{(IDN^2 + IDL^2} \quad \text{Eq. (35)}$$

em que: *IDN* e *IDL* são as distâncias norte-sul e leste-oeste entre dois pontos consecutivos, respectivamente. Para valores de *D* inferiores a 0,01 m, os pontos foram considerados como erro de posicionamento e foram eliminados.

Filtragem estatística

A filtragem estatística, classificada segundo Smiti (2020), como um método estatístico, não paramétrico, que leva em consideração intervalos interquartílicos para detecção de outliers. Esta etapa foi realizada foi realizada com base na metodologia proposta por Tukey (1997). Realizou-se uma análise exploratória dos dados, incluindo o cálculo da média, mediana, quartil superior (*QS*) e quartil inferior (*QI*), desvio padrão e coeficiente de variação. A partir dos quartis superior e inferior, foram estabelecidos os limites superiores (*LS*) e inferiores (*LI*) para a filtragem dos valores de produtividade, dados por:

$$LS = QS + 1,5(QS - QI) \quad \text{Eq. (36)}$$

$$LI = QI - 1,5(QS - QI) \quad \text{Eq. (37)}$$

MapFilter 2.0

O software permite realizar a filtragem estatística para remoção de erros grosseiros e posteriormente a filtragem espacial, por meio da avaliação comparativa de valores de produtividade de pontos próximos. É, portanto, uma filtragem primeiramente estatística e posteriormente localizada dos dados, baseado em distância, que considera os respectivos valores da vizinhança, sendo esta última isotrópica e anisotrópica. A partir da mediana, foram estabelecidos os limites superiores (*LimS*) e inferiores (*LimI*) para a filtragem dos valores de produtividade, dados por:

$$LimS = MK + MK \cdot v \quad \text{Eq. (38)}$$

$$LimI = MK - MK \cdot v \quad \text{Eq. (39)}$$

em que: *LimS* é o limite superior; *LimI* é o limite inferior; *MK* é a mediana de todos os valores localizados no conjunto de dados; *v* é a variação máxima aceita para a mediana.

Um outlier estatístico no conjunto de dados é um ponto com um valor maior ou menor que os limites de corte superior e inferior, respectivamente. O filtro local ocorre em duas etapas: filtros locais anisotrópicos e isotrópicos. O filtro anisotrópico desenvolvido por Maldaner e Molin (2020) foi originalmente usado para filtrar dados de produtividade na colheita de cana-de-açúcar, evitando comparativo com vizinhos laterais, que podem conter ausência de plantas (falhas). O filtro detectou todos os pontos localizados dentro de um raio (R) em torno de um ponto x_i dentro de uma única direção. O ponto x_i é comparado com k vizinhos anteriores e subsequentes, sendo k, o número de vizinhos cuja distância euclidiana é menor ou igual ao raio R (linha azul na Figura 1). A mediana desses k vizinhos foi calculada e as Eq. 4 e 5 foram aplicadas ao ponto x_i. Se o valor do ponto x_i foi maior ou menor do que os limites de corte superior e inferior, é considerado um outlier local e então excluídos do conjunto de dados. No filtro isotrópico, metodologia criada por Spekken et al. (2013), foi adaptada para identificar outliers em um conjunto de dados. O filtro isotrópico, ao contrário, detectou todos os k pontos vizinhos localizados em um raio R em torno de um ponto x_i em qualquer direção (Figura 1). Então, a mediana desses k vizinhos foi calculada e a Eq. 4 e Eq. 5 foram aplicadas ao ponto x_i. Enquanto o proposto por Spekken et al. (2013) adiciona peso para os pontos com valores fora do limite de corte, a metodologia do MapFilter 2.0 exclui o ponto x_i com um valor maior ou menor que o corte superior e inferior.

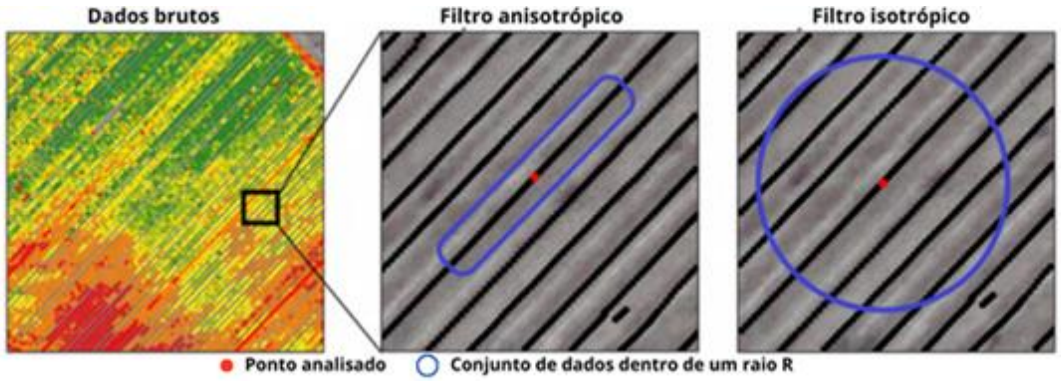


FIGURA 1. Filtragem local dos dados, isotrópica e anisotrópica (MALDANER et al., 2021).

Parâmetros de entrada para filtragem no MapFilter foram: 50% como variação máxima aceita para a mediana (*v)* para a filtragem estatística e 75% para a filtragem local do software, essas variações aceitas foram as mesmas para todos os talhões. O parâmetro que diferiu foi a dependência espacial, utilizando a largura média da plataforma de corte (Tabela 1) multiplicado por dez.

RESULTADOS E DISCUSSÃO

A Tabela 2 apresenta a frequência de erros obtida com o processo de pré-filtragem dos dados. A frequência de erros de produtividade nula (PN) apresentou valores que variaram entre 0,1 e 10,1%, enquanto as ocorrências de dados de umidade nula (UN) e distância nula (DN) foram muito baixas ou ausentes. Menegatti e Molin (2003), estudando seis diferentes monitores de produtividade, encontraram os valores variando entre 0,0 e 4,6% para (PN), 1,0 e 9,5% para (UN) e 0,0 e 11,5% para (DN).

TABELA 2. Frequência dos erros, dados de produtividade brutos e após filtragem estatística e local com o aplicativo MapFilter 2.0.

Frequência de erros (%)					Dados brutos			Dados após filtragem estatística				Dados filtrados no MapFilter 2.0			
ID	PN	UN	DN	LC	N	*x*	DP	N	*x*	DP	DR	N	*x*	DP	DR
						- - ton/ha - -			- -ton/ha- -		%		- -ton/ha - -		%
1*	1,55	0,00	0,21	-	81224	5,82	1,74	75467	6,00	1,21	7,08	68103	6,10	1,11	16,15
2*	0,24	0,00	0,10	-	21765	7,37	1,85	19889	7,53	1,23	8,62	19322	7,49	1,21	11,22
3*	0,70	0,00	0,00	-	29406	7,71	1,86	26364	7,74	0,90	10,34	25878	7,75	0,87	12,00
4*	2,22	0,00	0,00	-	81476	6,72	2,15	70011	7,24	0,95	14,07	67819	7,23	0,91	16,76
5*	0,34	0,00	0,00	-	72710	8,33	1,52	64600	8,31	0,58	11,15	66653	8,29	0,70	8,33
6*	0,72	0,00	0,00	-	56687	7,64	1,95	48919	7,95	0,90	13,70	49186	7,88	1,01	13,23
7*	1,22	0,00	0,00	-	106035	4,22	1,26	96408	4,34	0,79	9,08	89591	4,35	0,70	15,51
8**	2,05	0,00	0,00	-	64852	1,77	2,78	60325	1,76	0,24	6,98	59344	1,76	0,23	8,49
9**	10,11	0,00	0,00	-	16050	8,05	80,14	13665	7,05	1,63	14,86	12258	7,35	1,13	23,63
10**	0,28	0,00	0,00	-	31485	1,80	0,37	29872	1,83	0,27	5,12	29349	1,82	0,27	6,78

11**	1,39	0,00	0,00	-	106641	1,61	0,81	104672	1,62	0,71	1,85	66462	1,58	0,44	37,68
12**	0,11	0,00	0,00	-	35145	4,09	7,01	32697	3,63	1,24	6,97	21479	3,77	0,69	38,88

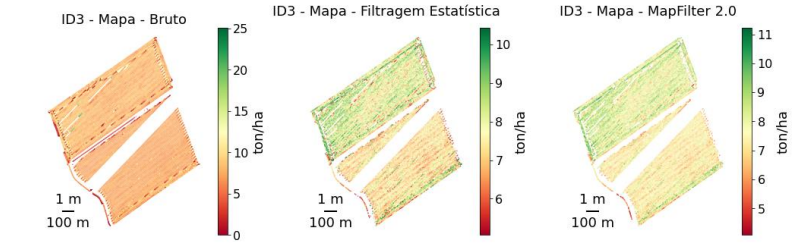
* milho; ** soja; PN: Produtividade Nula; UN: Umidade Nula; DN: Distância Nula; LC: Largura de Corte; N: Número de Pontos; *x*: Média; DP: Desvio Padrão; DR: Dados Removidos

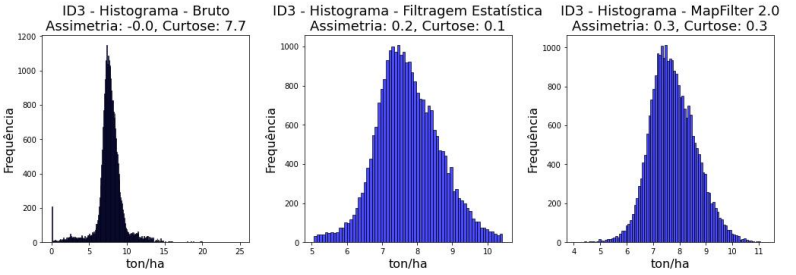
Com exceção do talhão 11, os demais tiveram redução de mais de 5% do total de pontos de produtividade, com valores variando entre 1,8 e 14,9% de dados removidos após a filtragem estatística. Com o uso do software MapFilter 2.0, com exceção dos talhões 5, 8 e 10, os demais tiveram redução de mais de 10% do total de pontos de produtividade, com valores variando entre 6,8 e 38,9% de dados removidos após a filtragem. A filtragem com o MapFilter 2.0 removeu, na média, 8,3% mais pontos, em comparação à filtragem estatística. Menegatti e Molin (2003), após realizarem filtragem dos dados de diferentes monitores, obtiveram resultados de remoção de pontos de produtividade de milho e soja na ordem de 4,6 a 27,3%. Gimenez e Molin (2004) relataram que o número de dados eliminados pelo filtro, utilizando funções de lógica, para realizar a eliminação dos erros foi bastante diferente em termos proporcionais, sendo eliminados 41% dos dados de soja e 21% dos dados de milho. Thylén et al. (2000), usando uma técnica de três etapas, removeram 10, 25 e 50% dos dados. O algoritmo de filtragem proposto por Simbahan et al. (2004) removeu entre 13 e 20% dos dados originais do monitor de produtividade de milho e soja, baseado em uma ordem lógica e sequencial de filtragem de dados, com a maioria da remoção ocorrendo durante a triagem primária de erros técnicos no processo de monitoramento da produtividade, resultados muito próximos aos encontrados por Sun et al. (2013), de 13,1 a 19,6%. De acordo com Zanella et al. (2018), os pontos removidos nos dados de produtividade de milho representaram 9,3 % do total de pontos. A maioria dos estudos sugere que a remoção de dados variou de 0,4 a 32% (SHEARER et al., 1997; BLACKMORE e MOORE, 1999; BECK et al., 2001; ROBINSON e METTERNICHT, 2005).

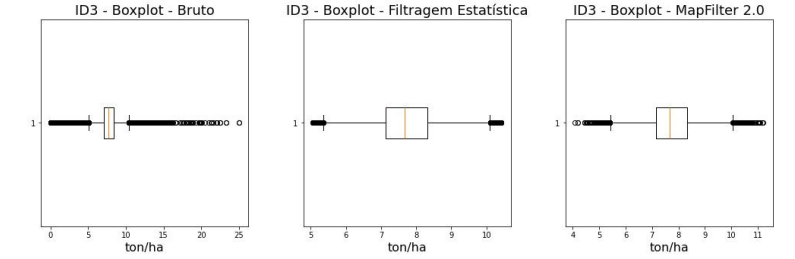
O aumento no valor da média de produtividade dos dados filtrados foi notado para a maioria dos talhões analisados, a qual se deve à eliminação de muitos pontos onde os valores de produtividade são bastante baixos, dado que corrobora com os estudos de Lyle et al. (2014).

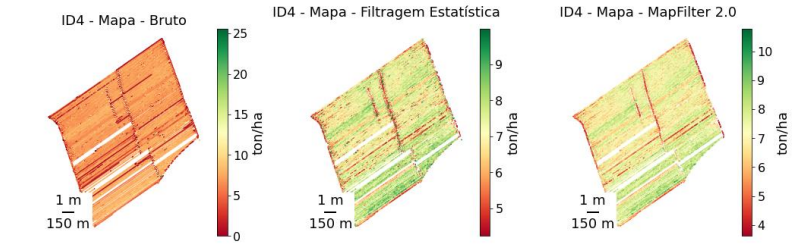
Em todos os casos da filtragem estatística houve uma redução do desvio padrão dos dados, com a menor redução, de aproximadamente 12%, no talhão 12 e maior redução, de 98%, no talhão 9, com média de 53%. O mesmo fenômeno ocorre com a filtragem no MapFilter 2.0, com a menor redução, de 27% no talhão 10 e a maior redução, de 99% no talhão 9, com média de 57,4%. Essas reduções ocorrem por conta de pontos de produtividade muito elevadas ou muito baixas com relação à média. Sun et al. (2013) também observaram a redução no valor do desvio padrão do conjunto de dados filtrados em relação aos dados não filtrados. Portanto, também ocorre redução do coeficiente de variação, devido aumento da média e redução do desvio padrão.

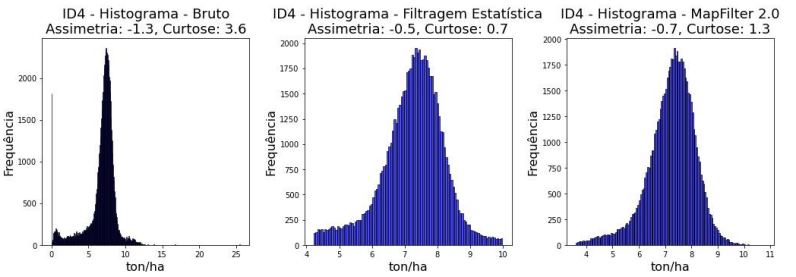
A Figura 2 apresenta alguns dos mapas de produtividade brutos e após filtragem estatística e local no MapFilter 2.0, onde é possível observar locais onde ocorrem maior remoção de pontos, identificados como de baixa produtividade, nas bordas dos talhões. Também apresenta os histogramas e os boxplots dos dados brutos, após filtragem estatística e após a filtragem local (MapFilter 2.0).

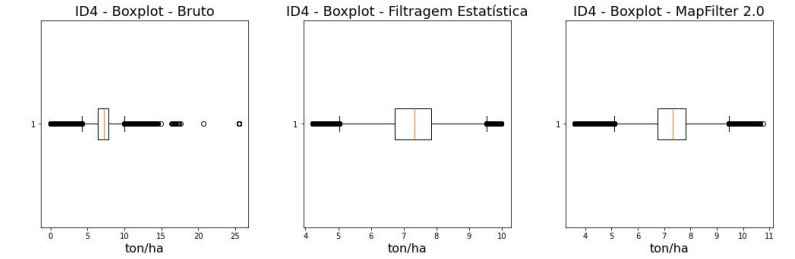

ID3 - Mapa - Bruto
ID3 - Mapa - Filtragem Estatística
ID3 - Mapa - MapFilter 2.0
ton/ha
1 m
100 m


ID3 - Histograma - Bruto
Assimetria: -0.0, Curtose: 7.7
ID3 - Histograma - Filtragem Estatística
Assimetria: 0.2, Curtose: 0.1
ID3 - Histograma - MapFilter 2.0
Assimetria: 0.3, Curtose: 0.3
Frequência
ton/ha


ID3 - Boxplot - Bruto
ID3 - Boxplot - Filtragem Estatística
ID3 - Boxplot - MapFilter 2.0
ton/ha


ID4 - Mapa - Bruto
ID4 - Mapa - Filtragem Estatística
ID4 - Mapa - MapFilter 2.0
ton/ha
1 m
150 m


ID4 - Histograma - Bruto
Assimetria: -1.3, Curtose: 3.6
ID4 - Histograma - Filtragem Estatística
Assimetria: -0.5, Curtose: 0.7
ID4 - Histograma - MapFilter 2.0
Assimetria: -0.7, Curtose: 1.3
Frequência
ton/ha


ID4 - Boxplot - Bruto
ID4 - Boxplot - Filtragem Estatística
ID4 - Boxplot - MapFilter 2.0
ton/ha

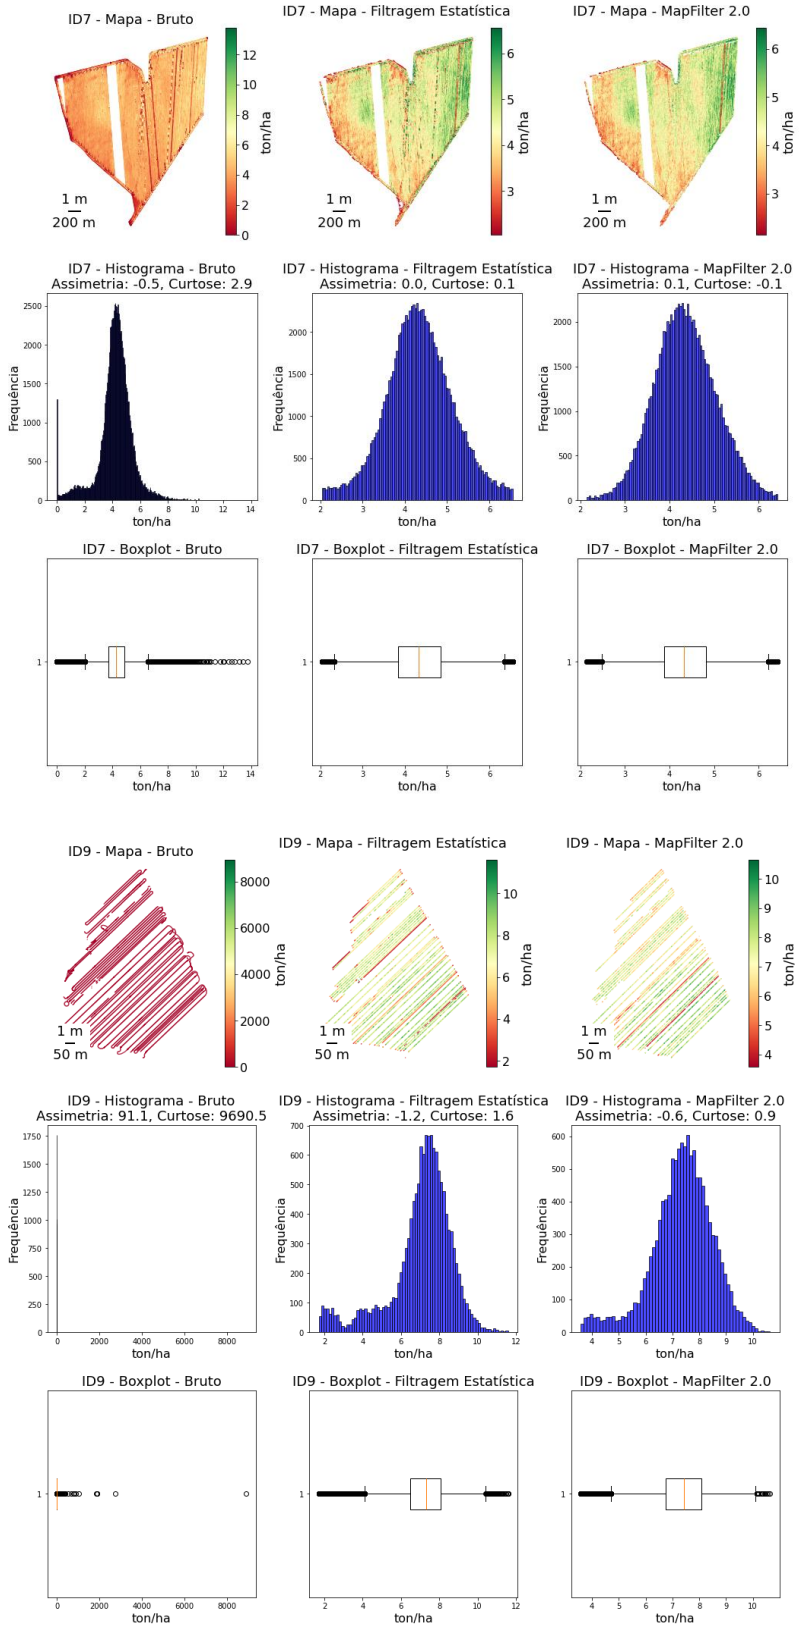


FIGURA 2. Mapas de produtividade, Histograma e boxplot dos dados brutos e após filtragem estatística e local no MapFilter 2.0 dos talhões 3, 4, 7 e 9.

Um desafio importante para avaliar o benefício da filtragem é a seleção de critérios de validação precisos (PING e DOBERMANN, 2005). Outro desafio é a potencial remoção de grandes quantidades de dados. Isso varia com base na abrangência dos algoritmos implementados e nos valores de limiar escolhidos. Diferentes filtragens de dados de produtividade provavelmente resultarão em diferentes quantidades e localizações de dados removidos. A remoção parcial de pontos de produtividade

errôneos pode não melhorar efetivamente a precisão do mapa, enquanto a remoção excessiva pode causar uma perda significativa de dados úteis de produtividade. Métodos para avaliar a filtragem podem ser utilizados, no presente trabalho utilizou-se parâmetros estatísticos, como distribuição de frequência, assimetria, curtose, média, desvio padrão, porcentagem de dados removidos, coeficiente de variação. No entanto existem outras ferramentas importantes para avaliar algoritmos de filtragem, e podem ser usadas para ajudar na seleção de parâmetros apropriados no processo de remoção de dados errôneos, como mapas de dados removidos, semivariogramas antes e depois da filtragem, e validação cruzada (jackknife) (SIMBAHAN et al., 2004).

A forma como os histogramas dos dados brutos se apresentam afasta do formato da distribuição normal, a qual é uma característica intrínseca da variabilidade espacial da produtividade no talhão, podendo ser resultado de registros imprecisos do monitor de produtividade da colhedora, que resultam em dados discrepantes. Após as filtragens o comportamento dos histogramas se altera, tomando uma forma que se aproxima à distribuição normal. Características estatísticas dos dados brutos de produtividade de grãos, sugeridas por Blackmore (2003), seria que os histogramas de rendimento derivados de conjuntos de dados de produtividade devem ser normalmente distribuídos. Isso é assumido porque, com a coleta de grandes números de observações de amostragem, a distribuição amostral se aproximará de uma forma normal, como previsto pelo Teorema do Limite Central (BETHEA et al., 1985). Utilizando dados obtidos de produtividade, Shearer et al. (1997, 2005) demonstraram que os dados brutos do monitor de produtividade pareciam ser normalmente distribuídos. Estudos adicionais usando análise de histograma encontraram dados de rendimento como não normais, existindo certa assimetria, com distribuições tanto positivas (NOACK et al., 2003b) quanto negativas (BECK et al., 2001). Lyle et al. (2014) apresentaram resultados de 183 campos com mapas de produtividade da Austrália Ocidental e mostraram que apenas 11% dos arquivos tinham uma distribuição normal, enquanto a maioria apresentava altos valores de assimetria positiva ou negativa.

Dado que a filtragem local leva em consideração a mediana local para realizar a filtragem, nota-se a presença de uma quantidade maior de outliers, ou seja, uma amplitude maior na dispersão dos dados mostrados pelos boxplot, quando comparado ao que representa o método estatístico. Essa é a grande vantagem da filtragem local com relação à filtragem estatística, pois ela leva em consideração as diferenças locais do talhão, não permitindo remover pontos que podem ser relevantes localmente.

CONCLUSÃO

A caracterização dos erros encontrados durante a pré-filtragem dos dados é um aspecto crucial. Essa caracterização e quantificação fornecem uma base para filtrar os pontos considerados como errôneos ou discrepantes, permitindo a melhoria da qualidade da informação contida nos mapas de produtividade. O processo de filtragem estatística removeu entre 1,8 e 14,9%, o software Mapfilter 2.0 entre 6,8 e 38,9% de dados errôneos e discrepantes, valores dentro dos limites que a maioria dos estudos sugere. Apesar dos erros ocorrerem em menor frequência nos monitores de produtividade atuais, alguns destes erros ainda persistem, principalmente relacionados aos valores decorrentes de leituras de produtividade nula. A etapa de filtragem de dados segue sendo fundamental para a obtenção de mapas de produtividade confiáveis.

REFERÊNCIAS

ARSLAN, S.; COLVIN, T. S. Mapeamento de rendimento de grãos: sensoriamento de rendimento, reconstrução de rendimento e erros. **Precision Agriculture**, 3, 135-154, 2002b.

BECK, A. D.; SEARCY, S. W.; ROADES, J. P. Yield data filtering techniques for improved map accuracy. **Applied Engineering in Agriculture**, 17(4), 432. 2001.

BETHEA, R. M.; DURAN, B. S.; BOULLION, T. L. **Statistical methods for engineers and scientists** (2nd ed.). New York: M. Dekker. 1985.

BLACKMORE, B. S.; MOORE, M. Remedial correction of yield map data. **Precis. Agric**. 1:53-66. 1999.

BLACKMORE, B.S. **The role of yield maps in precision farming**. National Soil Resources Institute. PhD.thesis. Cranfield University, Great Britain. 170 pp. 2003.

FULTON, J.; HAWKINS, E.; TAYLOR, R.; FRANZEN, A. Yield Monitoring and Mapping. In: **Precision Agriculture Basics**, p. 63-77, 2018.

GIMENEZ, L. M.; MOLIN, J. P. Algoritmo para redução de erros em mapas de produtividade para agricultura de precisão. Revista Brasileira de **Agrocomputação**, 2(1), 5- 10, 2004.

HAMILTON, C. J. Lat Lon Tools. 2023. Disponível em: < https://plugins.qgis.org/plugins/latlontools/ >. Acesso em: 20 jul. 2023.

LARK, R. M.; BOLAM, H. C.; STAFFORD, J. V. Limites para a resolução espacial de sistemas de mapeamento de rendimento para culturas combináveis**. Journal of Agricultural Engineering Research**, 66, 183-193, 1997.

LYLE, G.; BRYAN, B. A.; OSTENDORF, B. Métodos de pós-processamento para eliminar medições errôneas de rendimento de grãos: revisão e direções para futuros desenvolvimentos. **Precision Agriculture**, v. 15, n. 4, p. 377-402, 2014.

MALDANER, L. F.; MOLIN, J. P. Data processing within rows for sugarcane yield mapping. **Scientia Agricola** 77. 2020.

MALDANER, L. F.; MOLIN, J. P., SPEKKEN, M. Map Filter 2.0. 2021. Disponível em: < https://www.agriculturadeprecisao.org.br/softwares/ >. Acesso em: 22 jul. 2023.

MENEGATTI, L. A. A.; MOLIN, J. P. Metodologia para identificação e caracterização de erros em mapas de produtividade. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.7, n.2, p.367-374, 2003.

NOACK, P. H.; MUHR, T.; DEMMEL, M. Relative accuracy of different yield mapping systems installed on a single combine harvester. In J.V.Stafford and A. Werner (eds.), Proceedings of the 4th European conference on precision agriculture (pp. 445-451). Wageningen: Wageningen Academic Publishers. 2003b.

PING, J. L.; DOBERMANN, A. Processamento de dados de mapas de rendimento. **Precision Agriculture**, v. 6, p. 193-212, 2005.

QGIS Development Team. QGIS Geographic Information System. Open Source Geospatial Foundation Project. 2023. Disponível em: < http://qgis.osgeo.org >. Acesso em: 10 jul. 2023.

ROBINSON, T. P.; METTERNICHT, G. Comparing the performance of techniques to improve the quality of yield maps. **Agricultural Systems**, 85, 19-41. 2005.

SHEARER, S. A.; HIGGINS, S. G.; MCNEILL, S. G.; WATKINS, G. A.; BARNHISEL, R. I.; DOYLE, J. C.; LEACH, J. H.; FULTON, J. P. Post-Processing Correction to Improve the Accuracy of Yield Monitor Data in Grain Crops. In D. J. Mulla (ed.), Proceedings of the seventh international

conference on precision agriculture (pp. 173-186). MN, USA: Precision Agriculture Center, University of Minnesota. 2005.

SHEARER, S.A.; HIGGINS, S.G.; MCNEILL, S.G.; WATKINS, G.A.; BARNHISEL, R. I.; DOYLE, J. C.; LEACH, J. H.; FULTON, J. P. **Data filtering and correction techniques for generating yield maps from multiple combine systems.** Paper No. 971034. ASAE, St Joseph, MI, USA. 1997.

SIMBAHAN, G. C.; DOBERMANN, A. PING, J. L. Screening yield monitor data improves grain yield maps. **Agronomy Journal** 96, 1091-1102. 2004.

SMITI, A. A critical overview of outlier detection methods. **Computer Science Review**, Volume 38, 2020.

SPEKKEN, M.; ANSELMI, A. A.; MOLIN, J. P. A simple method for filtering spatial data. p. 259-266. In: Stafford, J.V., ed. Precision agriculture. Wageningen Academic Publishers, Wageningen, The Netherlands. 2013.

STAFFORD, J. V.; AMBLER, B.; LARK, R. M.; CATT, J. Mapping and interpreting the yield variation in cereal crops. **Computers and Electronics in Agriculture**, Volume 14, Issues 2-3, pp. 101-119, 1996.

SUN, W.; WHELAN, B.; MCBRATNEY, A.B. An integrated framework for software to provide yield data cleaning and estimation of an opportunity index for site-specific crop management. **Precision Agric** 14, 376-391. 2013.

THYLÉN, L.; ALGERBO, P. A.; GIEBEL, A. An expert filter removing erroneous yield data. In P.C. Robert et al. (ed.) Proc. 5th Int. Conf. on Precision Agriculture, Bloomington, MN [CD-ROM]. 16-19 July 2000. ASA, CSSA, and SSSA, Madison, WI. 2000.

TUKEY, J.W. **Exploratory data analysis**. 1 ed. v. 1. Reading, Massachusetts, 1977.

ZANELLA, M. A.; MARTINS, R. N.; GOMES, E. Q.; LIMA, A. N.; SANTOS, J. A. de S.; GONÇALVES, L. R. Remoção de erros em mapas de produtividade de milho via filtragem de dados brutos. In: SIMPÓSIO MATO-GROSSENSE DE MECANIZAÇÃO AGRÍCOLA E AGRICULTURA DE PRECISÃO - SIMAP, 1., 2018, Sinop. **Anais** [...]. Sinop: UFMT, Campus Universitário de Sinop, 2018.

APRENDIZADO DE MÁQUINAS NA PREDIÇÃO DO ÍNDICE DE ÁREA FOLIAR EM LAVOURA CAFEEIRA NA REGIÃO DE SANTO ANTÔNIO DO AMPARO-MG

AMARA LANA DE ABREU [1]; GABRIEL ARAÚJO E SILVA FERRAZ [2]; ROSALRA MARIA ALVES DE MORAIS [1]; FRANCK MORAIS DE OLIVEIRA [1]; ARTHUR CORREA DE NORONHA [1]

[1]BOLSISTA. Trevo Rotatório Professor Edmir Sá Santos Universidade Federal de, Lavras - MG, 37203-202. UNIVERSIDADE FEDERAL DE LAVRAS ; [2]DOCENTE . Trevo Rotatório Professor Edmir Sá Santos Universidade Federal de, Lavras - MG, 37203-202. UNIVERSIDADE FEDERAL DE LAVRAS

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Os modelos de aprendizado de máquinas estão sendo utilizados na agricultura como ferramenta de suporte à tomada de decisão e planejamento de sistemas de produção agrícolas, possibilitando a redução de impactos no rendimento das culturas, melhoria das produções agrícolas e na busca de um alto padrão produtivo, o que é almejado pelos produtores. O presente trabalho teve como objetivo predizer por inteligência artificial o índice de área foliar de uma lavoura cafeeira. O trabalho foi desenvolvido na Fazenda Bom Jardim, situada no município de Santo Antônio do Amparo no estado de Minas Gerais no mês de maio de 2023. Foram obtidas informações das plantas por uma régua graduada, os dados obtidos na coleta e no processamento foram: altura, diâmetro, volume e índice de área foliar (IAF) da planta cafeeira. Foram utilizados como dados de entrada volume, diâmetro e altura da planta e testado o modelo de aprendizagem KNN na estimativa do índice da área foliar. Ademais, foram realizados teste de validação cruzada com o modelo de aprendizagem para observar se a predição da variável resposta índice de área foliar foi bem realizada. Com as análises realizadas pode se afirmar que as variáveis, volume, diâmetro e altura da planta possibilitaram que estimador KNN pudesse realizar a predição do índice de área foliar na cafeicultura, apresentando boas métricas de MSE, RMSE, MAE, MAPE.

PALAVRAS-CHAVE: Inteligencia artificial; IAF; algoritmos

ABSTRACT

Machine learning models are being used in agriculture as a tool to support decision-making and planning of agricultural production systems, enabling the reduction of impacts on crop yield, improvement of agricultural production and the search for a high production standard, what is desired by producers. The present work aimed to predict the leaf area index of a coffee crop using artificial intelligence. The work was carried out at Fazenda Bom Jardim, located in the municipality of Santo Antônio do Amparo in the state of Minas Gerais in May 2023. Information was obtained from the plants using a graduated ruler, the data obtained during collection and processing were: height , diameter, volume and leaf area index (IAF) of the coffee plant. Plant volume, diameter and height were used as input data and the KNN learning model was tested to estimate the leaf area index. Furthermore, cross-validation tests were carried out with the learning model to observe whether the prediction of the response variable leaf area index was well performed. With the analyzes carried out, it can be stated that the variables, volume, diameter and height of the plant, enabled the KNN estimator to predict the leaf area index in coffee farming, presenting good metrics of MSE, RMSE, MAE, MAPE.

KEYWORDS: Artificial intelligence; IAF; algorithms

INTRODUÇÃO

O Brasil se enquadra como um dos maiores produtores mundiais de café, sendo que as áreas agrícolas brasileiras são grandes responsáveis na balança comercial do país. Técnicas de aprendizado de máquinas surgem como ferramentas essenciais para aprimorar ainda mais bancos de dados na agricultura visando alcançar melhores resultados e inferências aos produtores (Coutinho et al. 2016; Nascimento, 2019).A aprendizagem de máquina, segundo Muller e Guido (2017), resulta da convergência de diversas áreas do conhecimento, como matemática, estatística e ciência da computação. Essa sinergia viabiliza a realização de análises preditivas e classificatórias robustas. Conforme exemplificado por Alpaydin (2013), a aplicação de técnicas de aprendizado de máquinas (*machinelearning*) a grandes volumes de dados, permite a extração de padrões relevantes para fins como previsão, classificação e otimização de processos. A contínua alimentação de sistemas de aprendizagem de máquina com novos dados possibilita a construção de modelos preditivos cada vez mais precisos e autônomos, capazes de adaptar-se a diferentes cenários. As técnicas de Inteligência Artificial (IA) vem sendo bastante aplicadas na agricultura em diversas áreas, tendo como exemplo os trabalhos desenvolvidos por Gois et al. (2005), que aplicaram aprendizado de máquinas para estimar as médias de temperatura máxima e mínima do ar mensais de regiões do estado de Alagoas, trabalho de GÓMEZ (2020), utilizaram as ferramentas de aprendizados de máquinas para prever o rendimento de colheita de plantas anuais com base em informações sobre o consumo de defensivos agrícolas. Já ELAVARASAN et al. (2018)realizaram estimativas de rendimento na cultura de grãos com as variáveis resposta, condições climáticas. As técnicas de aprendizado de máquinas se mantêm em crescimento, trazendo progresso e oportunidades para o desenvolvimento dos pais em diferentes áreas e com diferentes variáveis abordadas sendo elas usadas para a predição ou para a classificação de informações. Neste contexto, o presente trabalho tem como objetivo predizer o índice de área foliar de áreas cafeeiras através de técnicas de aprendizado de máquinas, a partir de dados obtidos da cultura cafeeira.

OBJETIVOS

O presente trabalho tem como objetivo predizer o índice de área foliar de áreas cafeeiras através de técnicas de aprendizado de máquinas, a partir de dados obtidos da cultura cafeeira

MATERIAL E MÉTODOS

O estudo foi realizado na Fazenda Bom Jardim, localizada em Santo Antônio do Amparo, no estado de Minas Gerais, Brasil (FIGURA 1), nas coordenadas geográficas 21°00'58.9"S e 44°55'24.9"W, altitude média da área era de 950m.

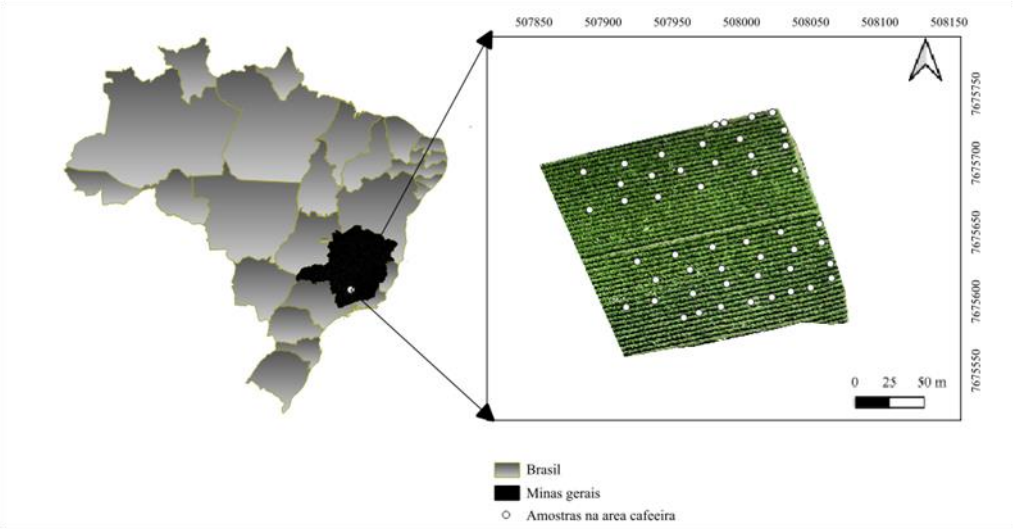


Figura 1. Localização do experimento

Os dados foram obtidos manualmente um a de forma aleatória nas plantas cafeeiras, onde foram coletados as informações altura e diâmetro das plantas, sendo que ao todo foram obtidos50 registros de cada variável no processo de medição. Para obtenção dos dados de altura e diâmetro da planta foi utilizado uma regra graduada conforme metodologia descrita por Ferraz et al.(2017). Para o cálculo da variável volume, foi utilizada as informações de altura e diâmetro da planta cafeeira conforme a equação de uma estrutura cilíndrica (equação 1).

$$V= 3.1415 *R^2 * H \quad (1)$$

O índice de área foliar foi calculado conforme descrito por Gonçalves et al. (2018), baseado na equação 2.

$$IAF=0,0134+0,7276 *D^2*H \quad (2)$$

Após este processo, foram aplicados modelos estatísticos de aprendizado de máquinas para analisar e para verificar a presença de outliers. O algoritmo de aprendizagem de máquinas KNN foi treinado na proporção 80% dos dados para treino e 20% dos dados para teste. O processamento do modelo KNN atua na predição de um novo vetor, calculando a média entre os k, gerado no processo de análise, o modelo escolhe os exemplos mais próximos, onde será baseada a variável resposta. Assim ocorre a predição a partir da combinação linear. No processamento foi realizado a validação cruzada do algoritmo KNN. As métricas utilizadas para avaliação de desempenho e acurácia do algoritmo na predição do IAF foram:o erro quadrático médio (MSE), a raiz do erro quadrático médio (RMSE), o erro absoluto médio (MAE) e o erro percentual absoluto médio (MAPE), visto que quando menor esses valores, informa-se que o algoritmo previu com eficácia. As análises foram realizadas no software Orange Canvas (Demsar et al., 2013).

RESULTADOS E DISCUSSÃO

Inicialmente foram realizados testes nos dados para observar se os dados apresentaram algum desbalanceamento através da analises descritivas, onde se constatou que não havia presença de outliers (Tabela 1).

Tabela 1 - Resultados da análise estatística descritiva das variáveis em estudo

Variável	NC	Media	Min	Max
IAF	50	8.26	0.36	63.69
Altura	50	2.69	0.28	3.64
Diâmetro	50	1.90	0.48	3.48
Volume	50	8.90	0.37	68.73

NC: número de dados, Min: mínimo, Max: máximo

Estudos realizados por Favarin et al. (2002) observaram valores médios diferentes para plantas cafeeiras de idades diferentes, onde encontraram IAF igual a 2,34 para cafeeiros com 30 meses e 3,41 para cafeeiros com 35 meses de idade. O Índice de Área Foliar é um indicador interessante, pois segundo Rezende et al. (2014), este pode ser importante para definir estratégias de manejos de irrigação e produção, alem de ser o indicador de produtividade,ou seja, qualquer variação do índice causada por fatores externos ou internos como por geadas, tempestades, desfolhas, seca, práticas de manejo, pode alterar a produtividade dos cafeeiros (BRÉDA, 2003).

Neste estudo o modelo KNN de aprendizado de máquinas. Assim, observou-se que o algoritmo KNN avaliado apresentou desempenho satisfatório pois os valores preditos pelo algoritmo se aproximaram dos valores reais do IAF. Observou-se que os valores das métricas de avaliação do algoritmo apresentaram valores baixos (Tabela.2), em que os indicadores de desempenho erro quadrático médio (MSE), raiz do erro quadrático médio (RMSE), erro absoluto médio (MAE), erro percentual absoluto médio (MAPE), apresentaram respectivamente valores iguais a 0,033; 0,182;0,037;0,006 , o que indica uma boa predição da ferramenta. Santos et al. (2014) afirmam que quanto menor o valor de MSE e RMSE melhor é a previsão do modelo, o classificando como uma boa ferramenta. O MAE como parâmetro também é uma medida importante, pois é menos sensível a outliers e a desbalanceamentos em bancos de dados.Todavia, Albuquerque (2023) apresenta métricas de MSE, MAE e RMSE abaixo de 0,50 para a avaliação de variáveis em campo para outras culturas agrícolas e outras variáveis de entrada com o modelo KNN.

Tabela 2. Métricas dos modelos

Modelo	MSE	RMSE	MAE	MAPE
KNN	0,033	0,182	0,037	0,006

Na Figura 2 é apresentado o modelo predito pelo KNN em função da variável Índice de área foliar (IAF). Tal figura representa a eficácia do modelo, visto que os pontos no gráfico de abscissa e ordenadas estão convergindo para o mesmo local, apresentando que o modelo criado pelo KNN foi capaz de predizer o IAF baseado nas informações provinda dos dados de entrada altura, diâmetro e volume com eficácia.

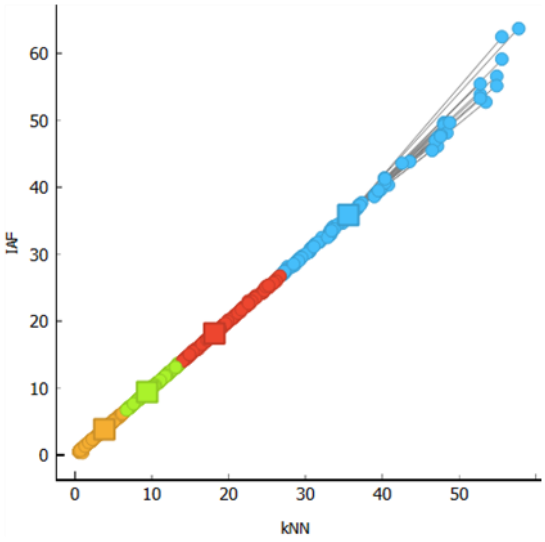


Figura 2. Modelo predito pelo KNN em função da variável Índice de área foliar (IAF)

CONCLUSÃO

A aplicação do algoritmo de aprendizado de máquinas do tipo KNN foi capaz de predizer o índice de área foliar dos cafeeiros utilizando os dados de entrada altura, diâmetro e volume, demonstrando potencial para estudos avançados nessa área.

AGRADECIMENTOS

EMBRAPA Café - Consórcio Pesquisa Café (projeto 10.18.20.041.00.00), CNPq (310186/2023-4), FAPEMIG (projetoAPQ-00661-22), CAPES, UFLA e PPGEA/UFLA.

REFERÊNCIAS

ALBUQUERQUE, A. P. A. Estimativa de rendimento de cultura aprimorada através da combinação de modelos de cultura e mineração de dados. 2023. Tese de Doutorado.

ALPAYDIN, E. Introduction to Machine Learning 3. ed. [S.l.]: The MIT Press, 2014.

BRÉDA, N. J. J. Ground-based measurements of leaf area index: a review of methods,instruments and current controversies. **Journal of Experimental Botany**, Oxford, v. 54,n.392,p.2403-2417,nov.2003.

COUTINHO, E. R.; SILVA, R. M.; DELGADO, A. R. S. Usingcomputationalintelligencetechnique for themeteorological data prediction. **Revista Brasileira de Meteorologia**, v. 31, p. 24-36, 2016.

DEMSAR. J; CURK. T; ERJAVEC. A; GORUP. C, HOCEVAR. T; MILUTINOVIC. M; MOZINA. M, POLAJNAR. M; TOPLAK. M; STARIC. A; STAJDOHAR. M; UMEK. L; ZAGAR. L; ZBONTAR. J; ZITNIK. M; ZUPAN. B. 2013. Orange: caixa de ferramentas de mineração de dados em Python. J Mach Aprenda Res 14(1): 2349-2353.

ELAVARASAN, D.; VINCENT PM, D.; SHARMA, V.; ZOMAYA, A.; SRINIVASAN, K. Previsão de rendimento integrando fatores agrários e modelos de aprendizado de máquina: uma pesquisa. Computadores e Eletrônica na Agricultura, v.155., 2018.

GOIS, G.; SOUZA, J. L.; SILVA, P. R. T.; JÚNIOR, J. F. O. Caracterização Da Desertificação No Estado De Alagoas Utilizando Variáveis Climáticas. **Revista Brasileira de Meteorologia** - RBMET, v.20, n.3, p. 301-314, 2005.GÓMEZ, C. A. R. Aplicação de aprendizado de máquina na agricultura de precisão. **Revista Cintex** , v. 25, não. 2 P. 14-27, 2020.

GONÇALVES. Estimativas de parâmetros biofisicos de lavoura de cafeeira a partir de imagens obtidas por aeronaves remotamente pilotadas.2018. Tese de Doutorado

MÜLLER, A. C.;GUIDO, S. Introduction to Machine Learning with Python. O'Reilly Media, Inc. 2017. https://doi.org/10.1007/978-3-030- 36826-5_10

NASCIMENTO, A. L. Estimativa de produtividade de café por meio de métodos de machinelearning. 2019. Tese de Doutorado

FERRAZ, Gabriel Araújo e Silva et al. Variabilidade espacial dos atributos da planta de uma lavoura cafeeira. Revista Ciência Agronômica, v. 48, n. 1, p. 81-91, 2017.

SANTOS, J. R. S.; CELESTE, A. B. Avaliação de estratégias de modelagem guiada por dados para previsão de vazão em rio sergipano. **Revista Ambiente & Água**, v. 9, p. 488-498, 2014.

ADULANÇO 4.0: UMA ATUALIZAÇÃO EM USABILIDADE PARA ANÁLISE DE DISTRIBUIDORES TRANSVERSAIS

Mateus Silva Gelain [1]; Gabriel Villela Bedum [1]; José Paulo Molin [2]
[1]Graduando. Piracicaba - SP. Escola Superior de Agricultura Luiz de Queiroz (ESALQ / USP); [2]Professor Titular. Piracicaba - SP. Escola Superior de Agricultura Luiz de Queiroz (ESALQ / USP)

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
A tecnificação da agricultura desempenha um papel de extrema importância para a sociedade, logo a adoção de ferramentas mais tecnológicas no campo é primordial para a promoção de um cultivo que atenda o tripé da sustentabilidade (econômico, ambiental e social). O segmento de fertilizantes e corretivos de solo é um exemplo desafiador, especialmente devido à grande expansão do uso de distribuidores a lanço e de taxas variáveis, que demandam maior atenção da caracterização do perfil de distribuição das máquinas. A definição da correta sobreposição das aplicações é fundamental, sendo executada pelo usuário de forma experimental, a partir da deposição realizada pela máquina. Para tal, um software utilizado é o Adulanço, hoje na versão 3.1 e o presente trabalho expõe a reformulação deste software, melhorando o modelo computacional com os objetivos de: (i) corrigir limitações anteriores; (ii) adicionar novos recursos; (iii) tornar mais eficiente o processamento e avaliação das máquinas distribuidoras a lanço; (iv) otimizar aspectos visuais, com o intuito de torná-lo intuitivo e autoexplicativos. É apresentada uma análise comparativa a fim de demonstrar as novas funcionalidades do Adulanço 4.0 frente à versão anterior. obteve-se um aplicativo versátil, que auxilia a execução do teste de campo e a partir dos dados obtidos facilita a tomada de decisão para a distribuição uniforme da aplicação por meio da sobreposição otimizada, em uma interface intuitiva.

PALAVRAS-CHAVE: Coeficiente de variação; Distribuidores centrípetos; Perfil de distribuição

ABSTRACT
The technology of agriculture plays an extremely important role for society, so the adoption of more technological tools in the field is essential for promoting cultivation that meets the tripod of sustainability (economic, environmental and social). Fertilizers and lime are challenging example, especially due to the great expansion in the use of spreaders and of variable rates, which demand greater attention in characterizing the distribution profile of the machines. Defining the correct overlap of applications is fundamental and is carried out by the user on an experimental basis, based on the deposition carried out by the machine. To this end, one of the software used is Adulanço, currently in its version 3.1 and this work presents the reformulation of this software, improving the computational model with the objectives of: (i) correcting previous limitations; (ii) add new features; (iii) make the processing and evaluation of spreaders distribution more efficient; (iv) optimize visual aspects, with the aim of making it intuitive and self-explanatory. A comparative analysis is presented in order to demonstrate the new features of Adulanço 4.0 compared to the previous version. A versatile application was obtained, which helps the execution of the field test and, based on the data obtained, facilitates decision-making for the uniform distribution of the application through optimized overlap, in an intuitive interface.

KEYWORDS: ;

INTRODUÇÃO

Com a evolução da agricultura brasileira, os patamares de produção da maioria das culturas cresceram. Em consequência, as plantas passaram a extrair maiores concentrações de nutrientes do solo, resultando a maior necessidade da utilização de fertilizantes e corretivos (CANTARELLA et al., 2022). Assim, é primordial a utilização eficiente destes recursos, com o intuito de otimizar o uso e minimizar impactos ambientais negativos decorrentes da sua má distribuição (HENRIQUE et al., 2012; MENDES et al., 2010).

Nesse contexto, a distribuição a lanço, que se intensifica no país, é feita com máquinas dedicadas que exigem a sobreposição otimizada entre passadas para minimizar a variação da quantidade depositada do insumo (GIOSA, 2022). Para definir a largura efetiva, após a sobreposição das passadas adjacentes, é necessário medir a deposição que a máquina produz para um determinado insumo. Assim, é fundamental a elaboração do perfil de distribuição do equipamento, obtido a partir da coleta e quantificação do produto acumulado transversalmente nos coletores. Com esses dados obtém-se a largura efetiva de trabalho em função do sistema de percurso, por meio da minimização do coeficiente de variação (CV) da deposição transversal (CUNHA e SOARES FILHO, 2016; REYNALDO e MACHADO, 2016; COSTA e SOUZA, 2018). Com a expansão da adoção de aplicações em taxas variáveis, são demandados maiores cuidados na preparação da máquina para as aplicações. A manutenção do perfil de distribuição para diferentes doses passa a ser um critério que a máquina deve cumprir (ASABE S573, 2018) e exige maior número de testes, contemplando diferentes doses para a mesma máquina e um mesmo produto.

O procedimento para a condução de testes de campo que permitem quantificar o CV da dispersão transversal dos produtos é descrito na norma ISO 5690/1 (ISO, 1982). No entanto, o processamento dos dados coletados não é trivial e pode ser facilitado com aplicativos que permitem definir e interpretar a largura efetiva da distribuição de insumos a lanço (GONÇALVES et al., 2001; MATOS, 2023). Um desses aplicativos é o Adulanço; criado há 30 anos, em ambiente DOS (*Disk Operating System*) e atualmente, em VBA (*Visual Basic Application*), de acesso livre a partir do Laboratório de Agricultura de Precisão da USP/ESALQ. E com a capacidade operacional das máquinas crescendo, também cresce a necessidade das interfaces digitais evoluírem (FARRET et al., 2008).

OBJETIVOS

Implementar melhorias no programa Adulanço aumentando a capacidade de dados analisados, facilitando a inserção dos dados, a visualização e a interpretação dos resultados, integração das antigas funcionalidades, além de inserir ferramenta de auto suporte.

MATERIAL E MÉTODOS

A identificação dos procedimentos que devem ser construídos permite o entendimento de quais linguagens de programação poderiam ser utilizadas para a elaboração do novo sistema. Nesse âmbito, buscou-se a adequação dos códigos originais, de forma mais prática, destacando procedimentos em Python e VBA, em que ambas são capazes de fornecer grande amplitude de bibliotecas para serem utilizadas. Entretanto, dentre as opções, a segunda linguagem oferece a possibilidade de explorar a construção visual em formulários. Atrelado a este fato, tem-se a possibilidade de utilizar todas as ferramentas de processamento de dados oferecidas pelo software Microsoft Excel (SME) (FERNADES, 2005), embora tal ambiente de programação apresente menor suporte ao programador por se tratar de uma linguagem mais antiga, com maior dificuldade à integração de novos procedimentos encontrados nos aplicativos atuais. O desenvolvimento e pesquisa de procedimentos atrelados às funcionalidades visuais para a versão 4.0 foram implementados, buscando um ambiente mais prático e intuitivo para a utilização e interpretação do sistema.

Para o planejamento dos aspectos abordados e reformulados, destacou-se as funções realizadas pela versão anterior em uma segmentação, que proporcionou a possibilidade de compreender as partes do sistema, e definir o ponto de partida para o projeto. Esforços foram direcionados para otimizar a interface, pouco intuitiva, que dificulta a utilização e interpretação da versão anterior. Paralelamente, buscou-se suprir as demandas do mercado atual relativo à largura de operação na distribuição de sólidos. Assim, seguiu-se o fluxograma de trabalho apresentado na Figura 1.

Foi imprescindível a adequação dos processos presentes na versão anterior, elaborando códigos operacionais atrelados a uma interface visual que torne mais intuitiva e simplificada a montagem do teste de campo e a inserção das massas de produto depositadas em cada coletor. Detectou-se e considerou-se a dificuldade encontrada por muitos usuários na montagem do teste de campo, especialmente no que diz respeito a quais coletores interpolar, por onde iniciar a disposição, quantos coletores devem estar entre os rodados, dentre outros. Observou-se ser necessária uma nova ferramenta atrelada ao teste de campo incumbida de efetuar um exemplo virtual do arranjo dos coletores.

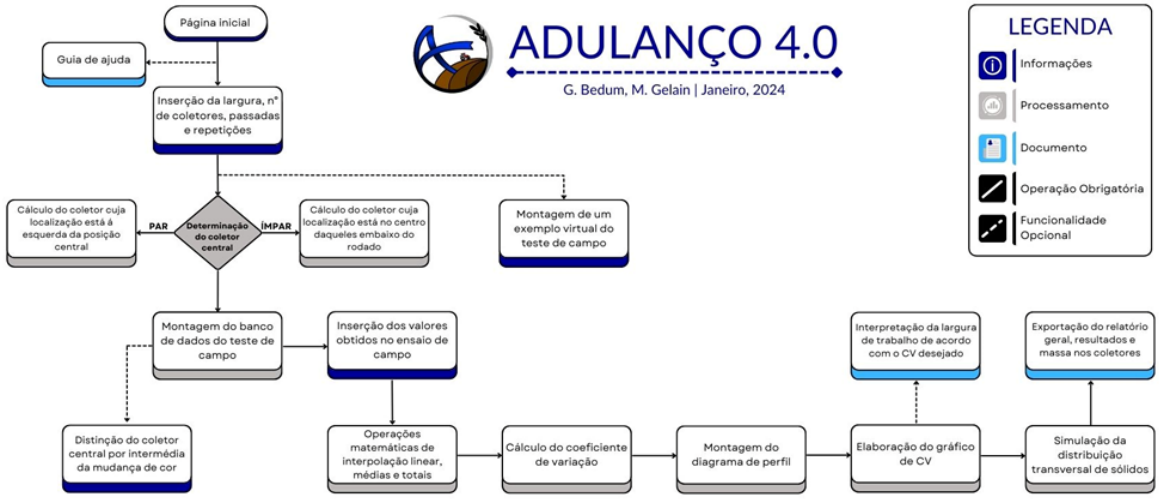


FIGURA 1. Fluxograma dos processos construídos e reformulados para a geração das funcionalidades da versão 4.0 do Adulanço. **Flowchart of the processes built and reformulated to generate the functionalities of version 4.0 of Adulanço.**

A formatação das bandejas em campo é um fator importante para a realização do teste. A norma ISO 5690/01, indica o uso de coletores em dimensão de 0,25 x 1,00 m ou de 0,50 x 0,50 m. No entanto, o sistema pode ser utilizado com outras medidas de bandejas diferentes destas, sendo obrigatório apenas que todos os recipientes apresentem a mesma dimensão, além de ser aconselhado o uso de um anteparo abafador para evitar que partículas ricocheteiem, especialmente com produtos granulados.

Na inserção dos valores coletados no teste, tem-se uma das principais funcionalidades, que é a interpolação linear dos dados, possibilitando a geração de novos valores para os espaços não coletados em campo. A interpolação linear realiza o ajuste de uma função polinomial de primeiro grau (Eq. 1). Dessa forma, uma vez estimada a equação da reta, é possível utilizar essa função para calcular valores de Y correspondentes a qualquer valor desejado de X (MEIJERING, 2002).

$$M = (Y1 - Y0)/J \qquad \text{Eq. (40)}$$

(1) Eq. 1,

em que: M - massa do material no coletor interpolado (g); Y0 - primeiro valor conhecido de um coletor (g); Y1 - próximo valor conhecido de um coletor (g); J - valor que representa a quantidade de vazios entre os valores conhecidos.

A partir da obtenção dos valores que caracterizam a massa contida nos coletores, torna-se possível, a partir do desvio padrão do conjunto (Eq. 2), efetuar o cálculo dos coeficientes de variação (Eq. 3), uma medida estatística que expressa a variabilidade relativa de um conjunto de dados (KENDALL e STUART, 1977).

$$DP = \sqrt{\frac{\sum(X_i - \bar{X})}{n}} \quad \text{Eq. (41)}$$

(2) Eq. 2,

em que: DP - desvio padrão; Xi - valor individual; - média dos valores; n - quantidade de valores.

$$CV = (DP/\bar{X}) * 100 \quad \text{Eq. (42)}$$

(3) Eq. 3,

em que: CV - coeficiente de variação.

A partir desses dados o software realiza a construção do gráfico de CV em função da largura efetiva, através da simulação de recobrimentos sucessivos com os valores acumulados nos coletores para cada situação, permitindo ao usuário interpretar as melhores larguras de trabalho para a máquina sob análise (MOLIN, 2009, MALDANER et al., 2016).

É apresentado um comparativo entre as versões 3.1 e 4.0 do programa proposto, para ser capaz de atingir e demonstrar os objetivos apresentados, em que é explorada a mesma base de dados em ambos os sistemas. Para propor a integração de novos recursos apresenta a possibilidade de o usuário exportar os dados coletados e os resultados de CV, para serem observados, além da geração de um relatório padrão com informações de todo o procedimento.

Para o sistema de ajuda, foi desenvolvida uma sequência de guias em formato PDF com instruções e explicações de cada funcionalidade oferecida pelo programa. Também se otimizou as funcionalidades do mecanismo computacional da simulação do perfil de distribuição transversal de produtos em dois sistemas de percurso, o alternado e o contínuo, que possibilita ao usuário compreender qual melhor se aplica à sua realidade.

RESULTADOS E DISCUSSÃO

Foram aplicados diferentes scripts para alcançar os resultados esperados, assim como a necessidade de adequar o design do sistema à sua identidade visual, através da aplicação de processamentos mais intuitivos. O desenvolvimento de janelas interativas em uma programação direcionada ao objeto, permitiu que o sistema migrasse de uma janela no SME para uma aplicação própria, que emula o programa. O menu lateral dinâmico apresenta as opções de navegação do sistema e interação com os dados, direcionando a ação do utilizador para evitar eventuais erros.

A entrada dos dados obtidos, que permite a construção virtual do teste realizado em campo, foi otimizada mediante a incorporação, em uma única janela, das funcionalidades de importação de dados de uma planilha padrão, concomitante a opção de edição de dados já cadastrados (Figura 2A). É necessário informar o número de repetições (fileiras de coletores) e o número de passadas sobre os coletores. Simplificou-se o processo relacionado à identificação do número do coletor central e paridade do mesmo, que passaram a ser encontrados automaticamente por funções ligadas ao SME.

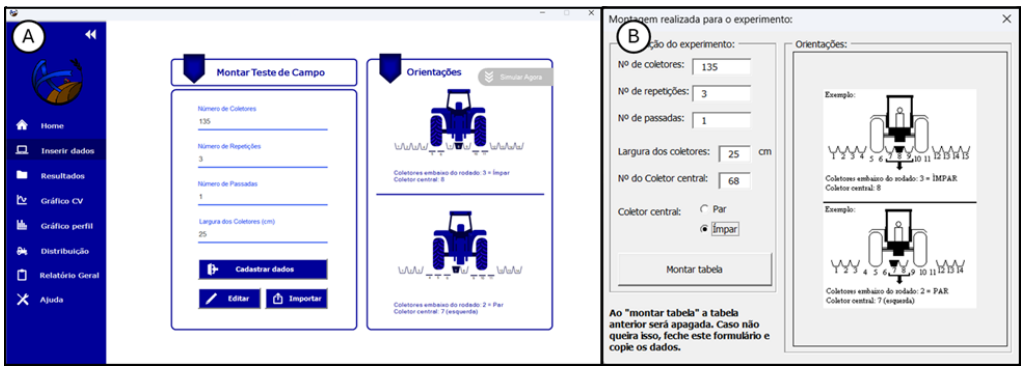


FIGURA 2. Tela de configuração para a entrada de dados na versão 4.0 do Adulanço (A) e na versão anterior (B). **Configuration screen for data entry in the Adulanço 4.0 version (A) and the old version (B).**

A nova ferramenta de montagem do teste de campo fornece um exemplo da posição dos coletores em campo. Por meio das informações de faixa de aplicação esperada, largura das bandejas, quantidade de coletores inexistentes a serem interpolados, quantidade de recipiente de sob a máquina (entre rodados) e finalizando com os coletores referentes ao espaçamento de um dos rodados. Como exemplo, para montagem de um teste com 34 m de faixa total de aplicação, obtém-se a sugestão da disposição dos 135 coletores de 0,25 m de largura (Figura 3). A construção de um sistema que identifica a posição de cada coletor, por meio de uma sequência de cálculos matemáticos, torna-se imprescindível para a facilitar a utilização do software.

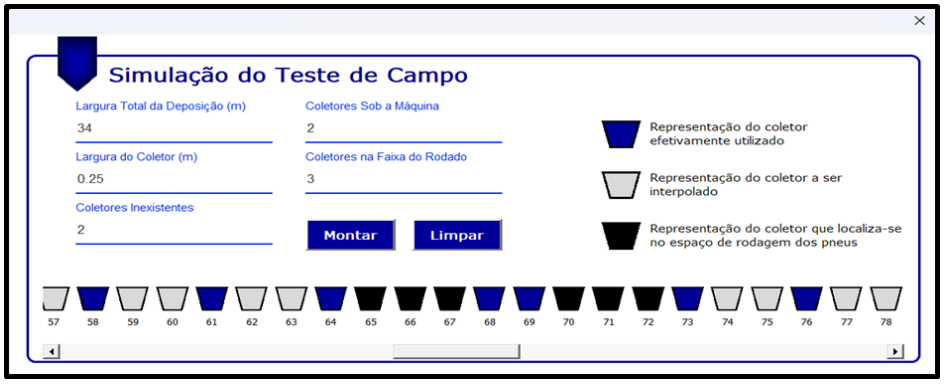


FIGURA 3. Janela referente ao módulo de simulação do teste de campo. **Window referring to the field test simulation module.**

Na atual versão o número máximo de coletores é de 98, que foi estendido para 200 coletores, suportando as situações de máquinas e de demandas de campo atuais. Os dados inexistentes, por conta da falta de coletores, são obtidos por interpolação a partir dos vizinhos (Figura 4).

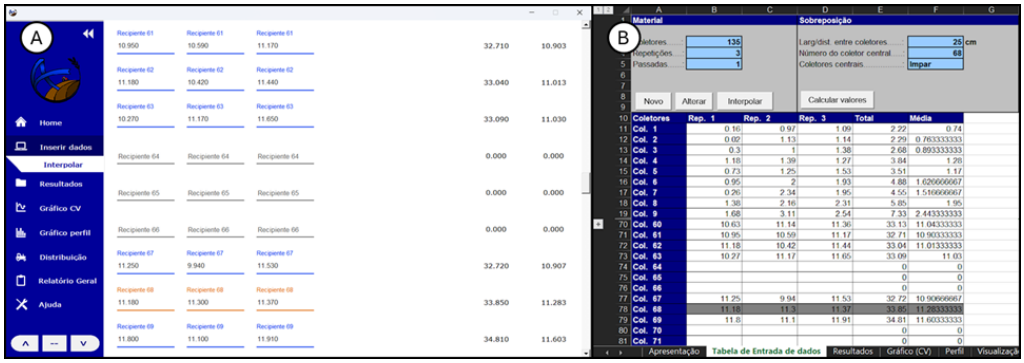


FIGURA 4. Tela de valores de produto nos coletores: Adulanço 4.0 (A); Adulanço 3.1 (B). **Product value screen in collectors: Adulanço 4.0 (A); Adulanço 3.1 (B).**

Para a modelagem do sistema que suporte maior número de coletores, foi desenvolvido uma janela contendo os componentes "Caixa de Textos", que propiciam a inserção dos dados obtidos no teste de campo. Com intuito de melhorar aspectos atrelados a visualização das informações, diferencia-se automaticamente por cor os campos preenchidos e não preenchidos. O software realiza operações lógicas para exibir com coloração distinta o coletor central, informação importante para direcionamento do usuário. Entretanto, a programação em ambiente VBA não apresenta compatibilidade com a funcionalidade de rolagem (*scroll*). Assim, foi adicionada na parte inferior do menu lateral a possibilidade de realizar deslizes rápidos para pontos específicos da página, como os coletores primários, intermediários e finais.

O CV é expresso graficamente, exibindo seu comportamento em função de todas as larguras de trabalho simuladas, para os diferentes tipos de percurso. Além de expor as informações em uma única janela e com alta resolução, destaca-se as colunas auxiliares que permitem ao usuário definir o CV desejado para sua aplicação em um determinado sistema de percurso. A partir de mecanismos computacionais, são indicadas as melhores larguras de trabalho para o cenário estabelecido (Figura 5).

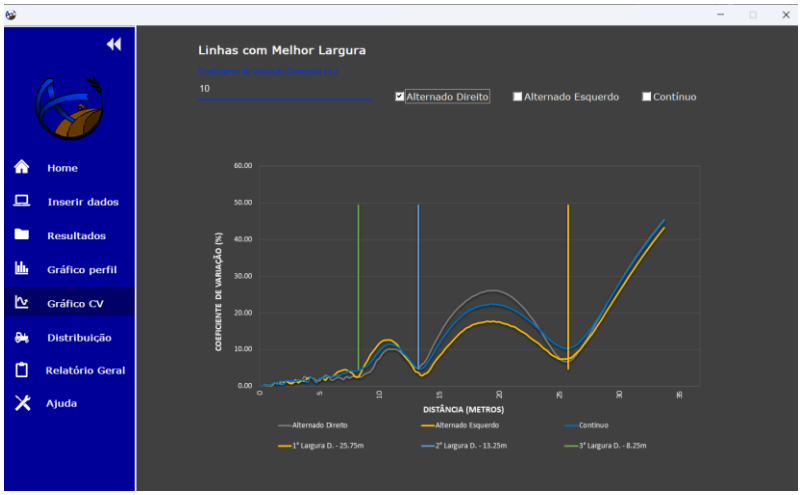


FIGURA 5. Tela para interpretação dos valores de CV, com colunas auxiliares informando as maiores distâncias no sistema alternado direito. **Screen for interpreting CV values, with auxiliary columns informing the greatest distances in the right alternating system.**

A nova proposta cria as passagens de simulação por meio de uma programação pura e direcionada a construção de objetos temporários. Pelo qual cada posição é calculada para criar uma coluna de deposição, em que quando conjugada a uma sequência forma a representação da simulação de passagem de um determinado equipamento e produto (Figura 6A). Complementarmente, foram incorporadas as linhas periféricas e central de passagem de cada máquina para ser possível identificar na somatória a posição intermediária e laterais da faixa de aplicação, facilitando a identificação das áreas de sobreposição (Figura 6B). Foi elaborada a funcionalidade de passar o mouse sobre as colunas, para identificar a quantidade de produto acumulado na posição em que se encontra.

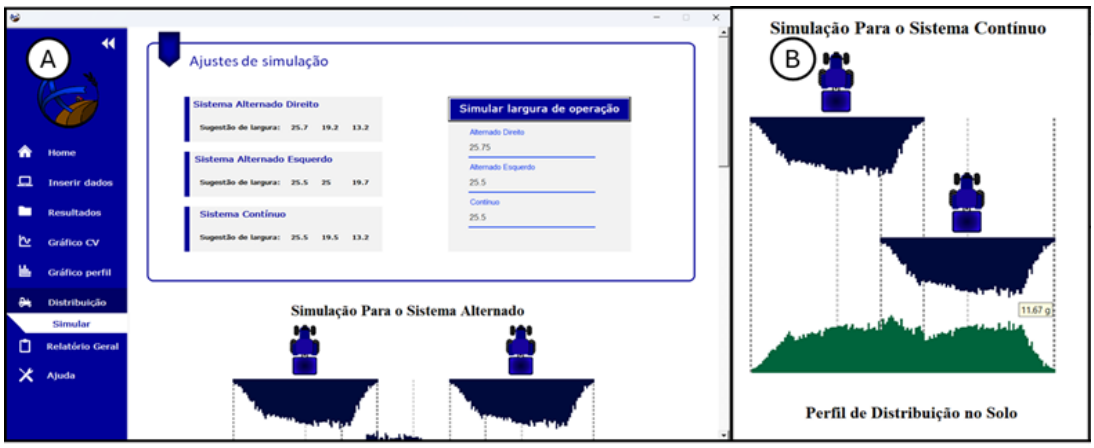


FIGURA 6. Tela de simulação de distâncias sugeridas: sugestões de largura a serem simuladas na versão Adulanço 4.0 (A); funcionalidade de verificação de valores depositados (B). **Suggested distance simulation screen: width suggestions to be simulated in the Adulanço 4.0 version (A); functionality for checking deposited values (B).**

A funcionalidade de gerar relatórios foi incorporada, permitindo ao usuário salvar as informações do projeto realizado. O novo ambiente propicia exportar no formato de tabela os valores das massas nos respectivos coletores, além dos resultados de CV nos diferentes sistemas de percurso. O software também incorpora ferramentas para a elaboração de um relatório geral, agregando informações a respeito do teste de campo, diagrama de perfil, gráfico de CV, resultados para cada sistema de percurso, além de exibir a simulação visual do perfil de distribuição transversal realizada pelo equipamento (Figura 7).

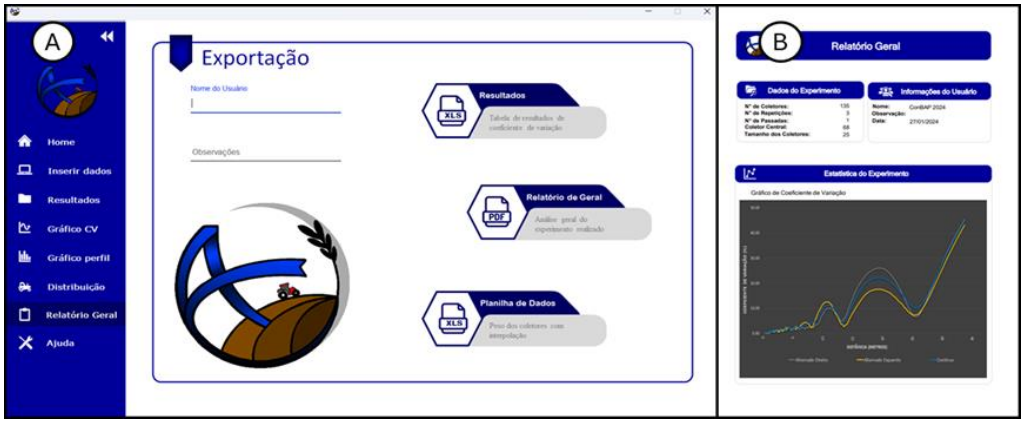


FIGURA 7. Aba dedicada à criação e exportação de relatório (A); página inicial do relatório (B)**. A represents a tab created for report export and B represents the home page of the general report.**

Com o intuito de auxiliar os usuários, a nova versão conta com mecanismos de direcionamento que apresentam interpretações padrões fundamentadas nos resultados de cada teste de campo. Portanto, consiste em uma estratégia importante para garantir a eficácia da comunicação, viabilizar a correta utilização do mecanismo computacional, promover a compreensão e estimular a participação ativa. Foi inserido um sistema de ajuda ao usuário, voltado para auxílio de acesso rápido (Figura 8). É disponibilizada uma série de notas com informações correspondentes a pontos críticos na utilização do aplicativo e na interpretação dos resultados.



FIGURA 8. Aba de ajuda da versão Adulanço 4.0 (A); exemplo de documentação referente a um processo do sistema (B). **A represents the help tab of the Adulanço 4.0 version and B represents one of the documentation referring to a system process.**

CONCLUSÃO

A atualização do aplicativo apresenta o potencial de otimizar a organização e análise de dados associados à distribuição transversal a lanço com as máquinas do mercado. Foi estendida a largura máxima de trabalho para 200 coletores. Os ajustes no mecanismo de interpolação, ao preencher os espaços vazios, melhora a visualização do perfil de distribuição e suaviza o gráfico de CV. A nova versão apresenta uma interface intuitiva e com recursos simplificados, o que permite ao usuário inserir dados de maneira rápida e precisa, facilitando a compreensão das etapas, com acesso simples à ajuda, quando necessário. O aplicativo viabiliza o acesso a uma visão da sobreposição e uniformidade da aplicação, permitindo a definição da melhor largura efetiva para cada condição de campo. Os gráficos, relatórios e análises implementadas no software facilitam a interpretação dos dados. A atualização adiciona novos recursos, torna mais eficiente o processamento e a avaliação das máquinas distribuidoras a lanço, e otimiza aspectos visuais, tornando-o mais intuitivo e autoexplicativo.

AGRADECIMENTOS

Ao Programa Unificado de Bolsas da USP pelo suporte financeiro aprovado no Edital 2023-2024.

REFERÊNCIAS

AMERICAN SOCIETY OF AGRICULTURAL AND BIOLOGICAL ENGINEERS. **ASABE S573 OCT2018**: Procedures for Evaluating Variable-Rate Granular Material Application Accuracy of Broadcast Spreaders. St. Joseph, Ml, EUA, 2018. 11p.

CANTARELLA, H.; QUAGGIO, J. A.; MATTOS, D; BOARETTO, R. M.; RAIJ, B. van.; (Eds.). **Recomendações de adubação e calagem para o Estado de São Paulo.** Campinas: Instituto Agronômico de Campinas, 2022. (IAC. Boletim Técnico, 100).

COSTA, LETÍCIA FERNANDA DA; SOUZA, MATHEUS HENRIQUE PEREIRA DE. **Comparação de dois sistemas de avaliação da qualidade de distribuição de fertilizantes por distribuidor centrífugo**, 2018. Trabalho de conclusão de curso (Curso Superior de Tecnologia em Mecanização em Agricultura de Precisão) - Faculdade de Tecnologia FATEC Shunji Nishimura (Pompéia), Pompéia, 2018.

CUNHA, J. P. A. R.; SOARES FILHO, R. Broadcast distribution uniformity of fertilizer with centrifugal spreaders used in variable rate application. **Engenharia Agrícola**, v. 36, 2016.

FARRET, I. S.; SCHLOSSER, J. F.; DURIGON, R.; WERNER, V.; KNOB, M. Variação da regulagem no perfil transversal de aplicação com distribuidores centrífugos. **Ciência Rural**, v. 38, n. 7, p. 1886-1892, out. 2008.

FERNADES, MAICRIS. **Desenvolvendo aplicações poderosas com Excel e VBA.** 1. ed. Florianópolis Visual Books, 2005. 126p.

GIOSA, LUCAS CAMPOS. **Qualidade em aplicações de fertilizantes sólidos granulados realizadas por distribuidor de mecanismo centrífugo.** 2022. Dissertação (Mestrado em Engenharia de Sistemas Agrícolas) - Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 2022. doi:10.11606/D.11.2022.tde-13092022-143645.

GONÇALVES, A. O.; MENEGATTI, L. A. A.; MOLIN, J. P. Adulanço 2.0: software para análise de distribuição transversal. **Congresso Brasileiro de Engenharia Agrícola**, 2001.

HENRIQUE, F.; BAIO, R.; JOSÉ, MOLIN, P.; JOSÉ, A.; LEAL, F. Avaliação comparativa da distribuição transversal de adubos sólidos aplicados em cobertura em culturas anuais instaladas. **Bioscience Journal** , v. 28, n. 4, p. 527-536, 3 set. 2012.

International standard organization. ISO 5690/1. **Equipment for distributing fertilizers - test methods - part 1: full width fertlizers distributors.** Isso standars handboook 13. Agricultural machinery. 1982.

KENDALL, M.; STUART, A. **The advanced theory of statistics.** 4.ed. London: Charles Griffin, 1977. v.1.

MALDANER, L.; CANATA, T.; MOLIN, J.; PASSALAQUA, B.; QUIRÓS, J. **Static and kinematic tests for determining spreaders effective width.** 13th International Conference on Precision Agriculture, July 31-August 4, St. Louis, Missouri, USA. 2016.

MATOS, GUSTAVO HENRIQUE HERVAL. **Uniformidade de distribuição de calda via aeronave remotamente pilotada.** 2023. Trabalho de Conclusão de Curso (Graduação em Agronomia) - Universidade Federal de Uberlândia, Uberlândia, 2023

MEIJERING, E. A chronology of interpolation: from ancient astronomy to modern signal and image processing. **Proceedings of the IEEE,** v. 90, n. 3, p. 319-342, 2002.

MENDES, A. M. S.; OLSZEVSKI, N.; SILVA, F. N. da; MENDES, R. L.; BRITO, L. T. de L. **Impactos ambientais causados pelo uso de fertilizantes agrícolas.** In: BRITO, L. T. de L.; MELO, R. F. de; GIONGO, V. (Ed.). Impactos ambientais causados pela agricultura no Semiárido brasileiro. Petrolina: Embrapa Semiárido, 2010. cap. 3, p. 55-99.

MOLIN, J. P et al. Adulanco 3.1. 2009.

REYNALDO, É. F.; MACHADO, T. M. Inspeção de distribuidores de fertilizantes sólidos na região centro sul do Estado do Paraná. **Revista Ceres**, v. 63, n. 6, p. 893-898, 2016.

ANÁLISE DE ÁREAS INSTÁVEIS E ESTÁVEIS EM SÉRIES TEMPORAIS MENSAIS DE PRECIPITAÇÃO PARA CULTIVO DA SOJA, MATO GROSSO - MT

Fabrícia Conceição Menez Mota [1,2]; Maria Carolina. da S. Andrea [1]; Rodrigo de S. Oliveira [1,3]; Edilson Freire R. Junior [1]; Victor Gabriel S, Barbosa [1]

[1]Cientista de Dados. Cuiabá - MT, Fone: (65) 3054-2232. Nuvem Tecnologia; [2]MBA - Data Science e Analytics. Piracicaba - SP. USP/Esalq; [3]Mestrando em Matemática, Estatística e Computação. São Paulo - SP. USP

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A precipitação é caracterizada por uma heterogeneidade espacial e temporal e a compreensão dessas variações é importante para gestão de áreas na agricultura. Este trabalho teve como objetivo (i) classificação dos meses, setembro, outubro, novembro e dezembro, em "meses padrão" para identificar a influência do fenômeno ENOS; e (ii) desenvolvimento de um algoritmo para identificar áreas estáveis e instáveis de perfis de precipitação mensais a fim de obter um mapa para gestão considerando a variabilidade espaço temporal, pixel a pixel. Analisou - se a precipitac?a?o mensal de setembro a dezembro, considerando o período da soja safra do Estado do Mato Grosso, foram coletados dados de 37 estac?ões meteorológicas locais no intervalo 2010 - 2022 e dados disponi?veis no site da National Weather Service Climate Prediction Center (NOAA) para análise da influência do feno?meno El Nin?o Oscilac?a?o Sul (ENOS). Evidencia-se uma considera?vel variabilidade mensal das precipitações para os setores analisados; A, B e C, não foi possível identificar uma padronização dos meses quanto a chuvoso e seco em relação ao fenômeno ENOS. O desenvolvimento do algoritmo permitiu a obtenção de um mapa para gestão das áreas em relação ao perfil de precipitação, análise da mudança no comportamento considerando a variabilidade pixel a pixel mensal para um conjunto de anos e assim identificar áreas que demandam diferentes ações de manejo visando a safra da soja para a área de estudo.

PALAVRAS-CHAVE: Algoritmo; Ciência de Dados; Sensoriamento Remoto

ABSTRACT

Precipitation is characterized by spatial and temporal heterogeneity and understanding these variations is important for area management in agriculture. This work aimed to (i) classify the months, September, October, November and December, into "standard months" to identify the influence of the ENSO phenomenon; and (ii) development of an algorithm to identify stable and unstable areas of monthly precipitation profiles in order to obtain a map for management considering space-time variability, pixel by pixel. Monthly precipitation from September to December was analyzed, considering the period of the soybean harvest in the State of Mato Grosso, data was collected from 37 local meteorological stations in the range 2010 - 2022 and data available on the National Weather Service Climate Prediction Center (NOAA) website) to analyze the influence of the El Niño Southern Oscillation (ENSO) phenomenon. There is considerable monthly variability in rainfall for the analyzed sectors; A, B and C, it was not possible to identify a standardization of rainy and dry months in relation to the ENSO phenomenon. The development of the algorithm allowed obtaining a map for managing areas in relation to the precipitation profile, analyzing the change in behavior considering monthly pixel-to-pixel variability for a set of years and thus identifying areas that require different management actions aimed at soybean harvest for the study area.

KEYWORDS: Algoritmos; Data Science; Remote Sensing

INTRODUÇÃO

Existem vários estudos que evidenciam um aquecimento global que persistira? por longo tempo, com evidências de mudanças climáticas (McPhaden et al., 2006; Cai et al., 2021). Têm sido realizadas inúmeras pesquisas de simulação dos seus efeitos sobre processos naturais e sobre atividades humanas, como sobre aumento do nível dos oceanos e de fenômenos climáticos extremos, sobre os biomas, produtividade vegetal, entre outros (Brasil, 2016). Essas mudanças têm influenciado a dinâmica dos sistemas produtivos na agricultura.

Para um melhor entendimento é necessário o estudo das flutuações climáticas. Dentre os fatores causais, que podem ter várias origens, eventos anômalos estão normalmente associados comumente aos eventos El Niño e La Niña, denominados de fenômeno ENOS (Kug et al., 2009; Kao et al., 2009). A mudança na temperatura do oceano Pacífico Equatorial, e na atmosfera adjacente, acarreta efeitos globais na temperatura e precipitação. O El Niño e a La Niña são partes desse mesmo fenômeno atmosférico-oceânico. O ENOS refere-se às situações nas quais o oceano Pacífico Equatorial está mais quente (El Niño) ou mais frio (La Niña) do que a média histórica (INPE, 2024).

A definição de regiões climáticas homogêneas têm sido o foco em muitos trabalhos, em várias partes do Brasil, grande parte dos estudos enfatizam a aplicação de clusterização para delimitação das áreas homogêneas de precipitação. Metodologia abordada nos trabalhos de Fechine e Galvincio (2008) para Pernambuco, Boschi, Oliveira e Assad (2011) para o Rio Grande do Sul, Dourado et al., (2013) para a Bahia e Santos et al., (2022) para o Estado de São Paulo. Nesta pesquisa será apresentado um algoritmo para delinear áreas estáveis e instáveis de precipitação fundamentado a partir da teoria desenvolvida por Blackmore (2000) e utilizado por Maestrini e Basso (2021) para identificação de zonas temporariamente instáveis de produtividade.

OBJETIVOS

O objetivo desse estudo foi identificar áreas estáveis e instáveis de perfis de precipitação considerando o período da soja safra no Estado do Mato Grosso, que compreende os meses de setembro a dezembro, para os anos de 2010 a 2022, ao longo de quatro épocas, a fim de avaliar a influência do número de anos na classificação das áreas. O desenvolvimento do algoritmo foi utilizado para obtenção de um mapa para delimitação de áreas semelhantes em relação à variabilidade da precipitação pixel a pixel.

MATERIAL E MÉTODOS

Caracterização da área de estudo

FIGURA 1 - Localização da área de estudo.

A área de estudo está localizada no Estado do Mato Grosso/Brasil. Foram selecionados três setores, A, B e C com 10.772; 4.837 e 4.096 hectares (ha) respectivamente (Figura 1). Foram analisados dados de 21 estações meteorológicas para o Setor A, 7 para o Setor B e 9 para o Setor C. O Estado do Mato Grosso apresenta duas Zonas Climáticas: Equatorial e Tropical Brasil Central (IBGE, 2022). Climaticamente o Estado apresenta duas estações bem definidas: período chuvoso, de outubro a abril; e o seco, de maio a setembro. As temperaturas médias mensais variam entre 23,00 °C e 26,84 °C e a precipitação anual total varia de 1.200 a 2.000 mm, com níveis mais altos no norte e leste-norte, e em regiões com altitudes próximas a 800m (SOUZA et al., 2013).

A área objeto de estudo pertence à Zona Climática Tropical Brasil Central, com temperaturas mais elevadas e com maior média de precipitação, localizada em sua grande parte no Bioma Amazônia e em área de transição Bioma Cerrado - Bioma Amazônia. As fitofisionomias predominantes na área

são: Floresta Estacional Sempre Verde, Floresta Estacional Sempre Verde Submontana, Savana, Savana Florestada IBGE (2019).

Meses padrão - Foi adaptada a metodologia de caracterização de anos hidrológicos, proposta por Monteiro (1976) para classificação de "meses padro?es". Considerando os diferentes graus de proximidade do ritmo "habitual" ao lado daqueles afetados por irregularidades na circulação. Classificando-os como meses habituais (Normais) e aqueles que com desvios positivos > 30, entre 15 a 30, 5 a 15 em relação às médias, são considerados, respectivamente, Chuvoso (C), Tendência a Chuvoso (TC), Normalmente a Tendência a Chuvoso (NTC), 5 a -5 mês Normal (N), enquanto meses com desvios negativos < -30, entre -15 a -30, -5 a 15 são definidos como Seco (S), Tendência a Seca (TS), Normalmente a Tendência a Seco (NTS). A classificação dos meses contribuirá para identificar a influência do fenômeno ENOS.

Os eventos de El Nin?o e La Nin?a foram identificados utilizando-se o I?ndice Ocea?nico Nin?o, que quantifica as anomalias na TSM do oceano Paci?fico, obtendo-se uma me?dia mo?vel de tre?s meses consecutivos, de acordo com o National Weather Service Climate Prediction Center (NOAA, 2023)

Algoritmo - Foi desenvolvido um algoritmo de percentis para delinear áreas estáveis e instáveis de precipitação, baseado na teoria desenvolvida por Blackmore (2000) e abordada em estudos realizados por McEntee et al. (2016), Yost et al. (2017) e Maestrini e Basso (2021). Nesse sentido, o algoritmo de percentis define a estabilidade de um pixel com base na sua classificação de percentis ao longo dos anos. As etapas do algoritmo, após construção de mapas mensais interpolados, utilizando o dado de precipitação da estação meteorológica mais próxima, são descritas a seguir:

(1) - Classificar a precipitação mensal em quatro categorias de acordo com os percentis 10, 50, 90 e 100;

(2) - Categorias - para cada período analisado, a) se o pixel variar do percentil 10 para o percentil 100 ou vice-versa, será considerado pixel instável, b) se o pixel permanecer no percentil 10 é considerado pixel estável - baixa precipitação, c) se o pixel permanecer no percentil 100 é considerado pixel estável - alta precipitação, d) pixel com ocorrência => 3 no percentil 50 (10 - 50) - pixel estável - baixa a média precipitação, e) pixel com ocorrência => 3 no percentil 50 (50 - 90) - pixel estável - média a alta precipitação e f) pixel indefinido;

(3) - Para análise pixel a pixel foram considerados quatro intervalos de períodos anuais entre os anos de 2010 a 2022 (I - 2010 a 2014; II - 2014 a 2018; 2018 a 2022 e 2010 a 2022); e

(4) - Foi utilizada a linguagem Python. Os dados foram interpolados para a área de estudo utilizando as bibliotecas: Pandas, Rasterio, Pykrige, Shapely, Sklearn, PIL e Geopandas, a partir das imagens em TIF geradas em python o *layout* dos mapas foram obtidos por meio do QGis (QGis Development Team, 2021).

RESULTADOS E DISCUSSÃO

Para melhor compreensão dos perfis de precipitação foram analisadas a precipitação mensal para cada setor analisado, no período de 2010 a 2022 (Figura 2). Como pode ser observado, para a área em análise o período chuvoso inicia no mês de setembro, contudo com valores baixos de precipitação, em meados de setembro, ocorre a liberação pelo Ministério da Agricultura, Pecuária e Abastecimento (MAPA) para plantio de soja no Estado do Mato Grosso.

Evidencia-se uma considera?vel variabilidade mensal das precipitações para os setores A, B e C, referente ao mês de setembro com destaque para o ano de 2014. Para o mês de outubro, o ano de 2015 apresentou baixos valores de precipitação para todos os setores, enquanto 2016 e 2017 teve menores

valores para o setor B e C. Já para o mês de novembro, cabe destaque para os anos de 2019 e 2020 com valores abaixo da média. Em dezembro, os anos de 2015 e 2019 também apresentaram valores abaixo da média para todos os setores, enquanto os anos de 2012 e 2020 apresentaram menores valores para os setores B e C.

Considerando os 13 anos analisados (2010 a 2022), aqueles associados com o El Nin?o não apresentaram um padrão determinado. para os anos de 2015 e 2019 os meses analisados performaram a níveis mais secos, somente o ano de 2018 que apresentou ser mais chuvoso. Sob a influência do índice La Nin?a, dos sete anos analisados, os anos de 2017, 2020 e 2022 foram mais secos, enquanto 2011 e 2021 foram mais chuvosos. Na condição de neutralidade, 2012 a 2014 também não se mostrou com padrão, houve meses chuvosos e secos (Tabela 1). Estudos realizados por Silva et. al., 2012 concluíram que não há um padrão com relação às mudanças na intensidade e distribuição das chuvas. Oliveira et al., 2015 constaram que as variações da Temperatura da Superfície do Mar (TSM) do oceano Pacífico não causam efeitos significativos ou evidentes no número de dias de chuva do Estado de Mato Grosso.

TABELA 1 -Índice Oceânico Nin?o para setembro, outubro e novembro (SON), Outubro, Novembro e Dezembro (OND), Novembro, Dezembro e Janeiro (NDJ) e Dezembro, Janeiro e Fevereiro (DJF) e a classificação dos meses de setembro a dezembro em Chuvoso (C), Tendência a Chuvoso (TC), Normalmente a Tendência a Chuvoso (NTC), Normal (N), Seco (S), Tendência a Seca (TS) e Normalmente a Tendência a Seco (NTS) para o período de 2010 a 2022. Percentual (%) de meses classificados entre (NTC a C) e (NTS a S).

			Setembro				Outubro				Novembro				Dezembro			% de meses	
			Setores				Setores				Setores				Setores				
ENOS	Ano	*SON	A	B	C	*OND	A	B	C	*NDJ	A	B	C	*DJF	A	B	C	NTC a C	NTS a S
La Niña	2010	-1.6	S	TC	S	-1.6	S	N	N	-1.6	TS	C	TC	1.5	C	C	N	41,7	33,33
La Niña	2011	-1.0	NTS	NTS	-	-1.1	C	C	C	-1.0	C	C	C	-1.4	C	C	C	**81,8**	**18,18**
-	2012	0.3	S	S	-	0.1	S	S	TS	-0.2	NTC	TC	N	-0.9	S	S	S	18,2	72,73
-	2013	-0.2	TC	S	NTS	-0.2	N	N	C	-0.3	N	NTS	NTS	-0.4	TC	C	N	33,3	33,33
-	2014	0.5	C	C	C	0.6	NTC	S	TS	0.7	TC	N	NTS	-0.4	C	C	C	66,7	25,00
El Niño	2015	2.4	S	S	-	2.6	S	NTS	S	2.6	NTS	S	S	0.5	S	S	S	0,0	100,0
La Niña	2016	-0.7	C	C	C	-0.7	TS	S	NTS	-0.6	N	N	TC	2.5	S	TS	NTC	41,7	41,67
La Niña	2017	-0.7	-	-	-	-0.8	TS	S	S	-1.0	NTS	TC	NTC	-0.3	S	S	N	22,2	66,67
El Niño	2018	0.8	C	C	C	0.9	C	C	C	0.8	C	C	C	-0.9	NTC	NTC	TC	100,0	0,00
El Niño	2019	0.3	S	S	S	0.5	C	TC	NTS	0.5	S	S	S	0.7	S	S	S	16,7	83,33
La Niña	2020	-1.2	S	S	S	-1.3	N	N	NTC	-1.2	S	S	S	0.5	NTC	S	S	16,7	66,67
La Niña	2021	-0.8	C	S	NTS	-1.0	C	NTC	NTC	-1.0	NTC	TC	C	-1.0	N	C	NTC	75,0	16,67
La Niña	2022	-1.0	S	C	NTC	-0.9	S	NTS	NTS	-0.8	NTS	TS	S	-1.0	N	S	NTS	16,7	75,00

* Dados obtidos pela NOAA, Períodos quentes (vermelho) e frios (azul) com base em um limite de +/- 0,5 o C para o Índice Oceanic Niño (ONI).

Para melhor compreensão da variabilidade da área de estudo a análise espaço temporal pixel a pixel mostrou-se importante para subsidiar na gestão de áreas para cultivo da soja safra. Para os períodos analisados, algumas áreas se mostraram com padrões para os pixels estáveis, conforme pode ser observado na Figura 3.

Considerando a classificação para o período de 2010 a 2022, a região sul do Setor C também apresentou o padrão de pixels instáveis e algumas áreas do Setor A para todos os meses analisados. Nesse período, houve registro de instabilidade de pixels no Setor B durante o mês de dezembro. Quanto maior a temporalidade de análise maior a probabilidade de um pixel mudar de classificação, pois é possível encontrar anos com condições climáticas extremas que revelarão a classificação correta do pixel potencialmente instável (Maestrini e Basso, 2021).

Cabe ressaltar que a falta de padronização de estabilidade para as áreas em análise pode ser justificada por um conjunto de outros fatores atuantes no estado do Mato Grosso, atuação da Alta da Bolívia (AB), da Zona de Convergência do Atlântico Sul (ZCAS); da Zona de Convergência Intertropical (ZCIT), e do Sistema Equatorial, Sistema Tropical Continental (STC), Sistema Tropical Atlântico (STA) e Sistema Polar Atlântico (SPA) (NIMER, 1972; ALVES, 2009). Tem -se as bandas de precipitação que é um fenômeno de mesoescala, apresentam escala horizontal em torno de algumas dezenas de quilômetro de largura, e uma escala temporal de poucas horas, podendo ser consideradas como bandas estreitas, em escalas de 10 km (Bennetts e Hoskins., 1979, Emanuel 1983, Innocentini e Caetano Neto., 1992). Segundo Monteiro (1962), frequentemente a regia?o Centro-Oeste e? dominada pela massa Tropical Atlântica (Ta) que, devido a? ação do anticiclone semifixo do Atlântico Sul, tem uma atuação bastante relevante durante o ano todo.

Em relação ao algoritmo desenvolvido nesse estudo foi atendido o objetivo de análise pixel a pixel para identificação de zonas estáveis e instáveis. Em suma, diversas metodologias e algoritmos já disponibilizados em várias ferramentas vêm sendo utilizados para zoneamento de áreas homogêneas e estáveis de precipitação. Como exemplo, citamos os estudos realizados por Santos et al., (2022) com análises pixel a pixel a fim de identificar áreas com aumento e redução de chuvas anuais utilizaram o programa RStudio para calcular o índice de precipitação normalizada e a inclinação de tendência (slope) da regressão linear. Dourado et al., (2013) identificaram zonas pluviometricamente homogêneas mediante análise de clusters utilizando o algoritmo k-means e o programa WEKA versão 3.6.3.

CONCLUSÃO

Em virtude da heterogeneidade temporal da chuva no decorrer do período analisado e de sua variabilidade mensal, não foi possível identificar uma padronização dos meses analisados quanto a chuvoso e seco em relação ao El Nin?o e La Nin?a. A metodologia desenvolvida e aplicada à análise espaço temporal (2010 a 2022) mostrou-se relevante para o alcance dos objetivos propostos, pois permitiu identificar áreas estáveis e instáveis para os meses de setembro a dezembro e subsidiar na gestão de áreas para cultivo da soja safra.

REFERÊNCIAS

Alves, L. M. Clima da regia?o centro-oeste do Brasil. In: Cavalcanti, I.F.A.; Ferreira, N.J.; Silva M.G.A.J.; Dias, M.A.F.S. (2009). Tempo e Clima no Brasil. São Paulo: Oficina de Textos, Cap. 15, 463 p.

Bennetts, D.A.; Sharp, J.C.(1982). The relevance of conditional symmetric instability to the prediction of mesoscale frontal rainbands. Quarterly Journal of the Royal Meteorological Society, 108,(457):595-602, July.

Blackmore, S. (2000). The interpretation of trends from multiple yield maps. *Computers and Electronics in Agriculture, 26*, 37-5. https://doi.org/10.1016/S0168-1699(99)00075-7

Boschi, R.S.; Oliveira, S.R.M.; Assad, E.D. (2011). Técnicas de mineração de dados para análise pluvial decenal do Rio Grande do Sul. Engenharia Agrícola, v.31, p.1189-1201. DOI: 10.1590/S0100- 69162011000600016

Brasil. Ministe?rio da Cie?ncia, Tecnologia e Inovac?a?o. (2016). Modelagem clima?tica e vulnerabilidades Setoriais a? mudanc?a do clima no Brasil. Brasi?lia: Ministe?rio da Cie?ncia, Tecnologia e Inovac?a?o. 590p. ISBN: 978-85-88063-30-3.

Cai, W. et al. (2021). Changing El Niño-Southern Oscillation in a warming climate. *Rev. Earth. Environ.* 2, 628-644.

Dourado, C. S.; Oliveira, S. R. M.; Avila, A. M. H. (2013). Análise de zonas homogêneas em séries temporais de precipitação no Estado da Bahia. Bragantia, Campinas, v. 72, n. 2, p.192-198.

Emanuel, K.A. (1983). On assessing local condicional symmetric instability from atmospheric soundings. Monthly Weather Review,Oct, 111(10):2016-2033.

Fechine, J.A.L.; Galvincio, J.D. (2008). Agrupamento da precipitação mensal da bacia hidrográfica do rio Brígida-PE, através da multivariada. Revista Brasileira de Geografia Física, v.1, p.39-46.

INPE-Instituto Nacional de Pesquisas Espaciais. (2024). Condições atuais do ENOS: Caracterização do El - Niño. Disponível em: http://enos.cptec.inpe.br Acesso em: 15 fev. 2024.

IBGE - Instituto Brasileiro de Geografia e Estatística (2022). Disponível em: http://landpage-h.cgu.gov.br/dadosabertos/index.php?url=http://www.geoservicos.ibge.gov.br/geoserver/wms?service=WFS&version=1.0.0&request=GetFeature&typeName=CREN:ClimadoBrasil_5000&outputFormat=SHAPE-ZIP Acesso em: 13 fev. 2024.

IBGE - Instituto Brasileiro de Geografia e Estatística (2019). Biomas e sistema costeiro-marinho do Brasil: compatível com a escala 1:250 000 / IBGE, Coordenação de Recursos Naturais e Estudos Ambientais. - Rio de Janeiro: IBGE, 2019. 168 p. - (Relatórios metodológicos, ISSN 0101-2843; v. 45).

Innocentini, V.; Caetano Neto, E.S. (1992). A numerical study of the role of humidity in the updraft driven by moist slantwise convection. Journal of the Atmospheric Sciences, July.49(13):1092-1106.

Kao, H. Y. & Yu, J. Y. (2009). Contrasting eastern-Pacific and central-Pacific types of ENSO. *J. Clim.*22, 615-632.

Kug, J. S., Jin, F. F. & An, S. I. (2009). Two types of El Niño events: cold tongue El Niño and warm pool El Niño. *J. Clim.* 22, 1499-1515.

McPhaden, M. J., Zebiak, S. E. & Glantz, M. H. (2006). ENSO as an integrating concept in earth science. *Science* 314, 1740-1745.

Mastrini, B., Basso. B.Maestrini. (2021). Subfield crop yields and temporal stability in thousands of US Midwest fields. *Precision Agriculture* 22:1749-1767, https://doi.org/10.1007/s11119-021-09810-1.

Monteiro, C. A. de F. O Clima e a organização do espaço no Estado de São Paulo: problemas e perspectivas. São Paulo, Serie Teses e Monografias, 28, USP/IGEOG, 1976.

McEntee, P., Bennett, S., Belford, R., Harper, J., & Trotter, M. (2016). Mapping the stability of spatial production in integrated crop and pasture systems: towards zonal management that accounts for both yield and livestock-landscape interactions. In *13th international conference on precision agri- culture* p. 1-13.

Nimer. E. (1972). Climatologia do Brasil: Introdução a? Climatologia Dina?mica. Revista Brasileira de Geografia, Rio de Janeiro, v. 34, n. 4; p. 3-30.

NOAA- National Oceanic and Atmospheric Administration. (2023). Climate Prediction Center: Historical El Nino / La Nina episode**s** (1950-2023). Disponível em: https://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ONI_v5.php Acesso em: 13 fev. 2024.0-5

INLA, UMA ALTERNATIVA A O USO DA KRIGAGEM NA ANÁLISE DE SOLO

Lucas Monteiro Bianchi [1,2]; Fabrícia Conceição Menez Mota [2]; Cristiano Ferreira de Oliveira [2]; Rafael Carlos dos Santos [2]; Caio Marchiorato de Gouveia [2]

[1]Pesquisador. Manguinhos, Rio de Janeiro - RJ. Escola Nacional de Saúde Pública/Fiocruz; [2]Cientista de dados. Cuiabá, Mato Grosso. Nuvem Tecnologia

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A análise do solo é uma ferramenta importante para determinar a quantidade de cada nutriente presente, permitindo a aplicação adequada de fertilizantes para corrigir possíveis desequilíbrios. Com o avanço computacional, muitos métodos de interpolações foram surgindo e não diferente disso, na estatística outra área passou a ganhar força, a bayesiana. Este estudo apresenta uma alternativa à krigagem, método usualmente empregado para a interpolações. Se distanciando também dos métodos bayesianos mais utilizados como o MCMC, essa alternativa, o INLA (*Integrated Nested Laplace Approximation*), não utiliza simulações, consequentemente sendo mais eficiente computacionalmente. Essa metodologia também permite mensurar a relação de efeitos causados por outras variáveis considerando as suas respectivas distribuições espaciais. Assim, foram utilizados dados pontuais de amostras de solo para K, Ca, Mg, S, B, Cu, Fe, Mn, Zn e P, elementos classificados como essenciais para o estímulo do crescimento de plantas. A variável de interesse interpolada é a saturação de bases trocáveis (V%). Essa medida é importante para entender a fertilidade do solo e sua capacidade de reter nutrientes essenciais para o crescimento das plantas. Esse método se demonstrou ser uma robusta alternativa à krigagem e ainda apresentou o mapa das incertezas referentes as estimações obtidas.

PALAVRAS-CHAVE: INLA; Interpolação; Análise de solo

ABSTRACT

Soil analysis is an important tool for determining the amount of each nutrient present, allowing the appropriate application of fertilizers to correct possible imbalances. With computational advances, many interpolation methods emerged and not unlike that, in statistics another area began to gain strength, Bayesian. This study presents an alternative to kriging, a method usually used for interpolation. Also distancing itself from the most widely used Bayesian methods such as MCMC, this alternative, INLA (Integrated Nested Laplace Approximation), does not use simulations, consequently being more computationally efficient. This methodology also allows measuring the relationship of effects caused by other variables considering their respective spatial distributions. Thus, specific data from soil samples were used for K, Ca, Mg, S, B, Cu, Fe, Mn, Zn and P, elements classified as essential for stimulating plant growth. The interpolated variable of interest is the saturation of exchangeable bases (V%). This measurement is important for understanding soil fertility and its ability to retain essential nutrients for plant growth. This method proved to be a robust alternative to kriging and a map of uncertainties relating to the estimates obtained is also presented.

KEYWORDS: ;

INTRODUÇÃO

Psicologicamente, estamos fadados a confiar em mapas. Embora essa predisposição exista, é fundamental compreender as incertezas inerentes à construção de mapas e assim oferecer uma camada extra de confiança ao usuário (MCBRATNEY, 1992). Ao longo de décadas, diversos autores

propuseram diferentes métodos para identificar e minimizar as incertezas associadas à estimação de variáveis espacialmente distribuídas (HEUVELINK, 2006; MCBRATNEY, 1998). Qualquer metodologia que vise a geração de mapas sofre de erros, incluindo erros de interpolação. Assim, é importante quantificar a incerteza associada aos mapas produzidos (POGGIO, 2016). A falta de avaliação da incerteza não fornece informações sobre a confiabilidade das previsões, limitando o potencial de tomada de decisão (MCBRATNEY, 1992).

Visando estimar a incerteza, a abordagem bayesiana tem se destacado. O uso de simulação de Monte Carlo via cadeias de Markov (MCMC) tem sido amplamente utilizada na inferência Bayesiana, principalmente quando é necessário estimar o valor integral de funções que não são analiticamente resolvíveis. Seu método consiste em realizar amostragens de uma cadeia de Markov estacionária que possui distribuição igual à distribuição a posteriori (BASTOS, 2018). Entretanto, ao considerar a dependência espacial, as estimações dos parâmetros pelo método MCMC se tornam algo computacionalmente ineficientes e podem produzir elevados valores para a estimativa dos erros dos parâmetros (KNORR-HELD, 2000). Rue, Martino e Chopin (2019) apresentaram um novo método que utiliza aproximações de Laplace para aproximar as distribuições a posteriori via métodos computacionais determinísticos, o *Integrated Nested Laplace Approximation* (INLA), cujo qual não utiliza simulações, ou seja, não é necessário verificar convergência, pois é um método determinístico.

O conhecimento da variabilidade espacial dos atributos do solo e da cultura são informações que tornam possível a aplicação de sistemas de manejo específico e podem ser obtidos através de mapas interpolados (DALCHIAVON, 2017). Um exemplo disso é a elaboração de mapas de fertilidade do solo permite que sejam aplicados os nutrientes de acordo com a necessidade pontual, assim melhorando a eficiência da aplicação. Dessa forma, o objetivo desse trabalho é apresentar uma técnica mais robusta que os métodos normalmente utilizados, capaz de lidar com um conjunto de variáveis que podem exercer alguma influência na variável resposta e assim, gerar estimações mais confiáveis. Como exemplo prático, foi modelado a saturação de bases trocáveis (V%), sendo esta explicada pelas variáveis essenciais para o desenvolver da planta, K, Ca, Mg, S, B, Cu, Fe, Mn, Zn e P.

OBJETIVOS

Propor uma técnica mais robusta que a krigagem, que seja capaz de lidar com um conjunto de variáveis que possam exercer alguma influência na variável resposta e assim, gerar estimações mais confiáveis.

MATERIAL E MÉTODOS

MÉTODOS: Este estudo ajustou um modelo geoestatístico bayesiano como modelo gaussiano latente, dentro da estrutura INLA e utilizando equações diferenciais parciais estocásticas (SPDE) para modelagem da correlação espacial (INLA+ SPDE). A geoestatística baseada em modelos usando INLA e SPDE tem sido empregada para previsão espacial em uma ampla gama de aplicações, incluindo poluição do ar na Itália (CAMELETTI, 2013), leptospirose no Brasil (HAGAN, 2016) e malária em Moçambique (MORAGA, 2021). A geoestatística baseada em modelos também fornece uma abordagem flexível para combinar vários dados disponíveis em diferentes resoluções espaciais para obter melhores previsões do que aquelas obtidas usando apenas um tipo de dados (ZHONG, 2023). Na abordagem da equação diferencial parcial estocástica (SPDE), assumimos que subjacente aos dados observados, existe uma variável espacialmente contínua que pode ser modelada usando um campo aleatório gaussiano (GRF) com função de covariância de Matérn que é definida como

$$Cov\left(x(s_i),x(s_j)\right) = \frac{\sigma^2}{2^{v-1}\Gamma(v)}\left(k||s_i - sj||\right)^v K_v\left(k\left||s_i - s_j\right|\right) \quad (1)$$

em que,

σ^2 Eq. (43)
denota a variância marginal do campo espacial,

$K_v(.)$ Eq. (44)
refere-se à função de Bessel de segundo tipo modificada e ordem

$v > 0$ Eq. (45)
. O valor de

v Eq. (46)
determina a suavidade do campo e é geralmente fixa, pois é complicado estimar para situações

$k > 0$ Eq. (47)
. Mais detalhes sobre a teoria e implementação do INLA podem ser encontrados em Rue et al. (2009), Martins et al. (2012), Blangiardo et al. (2013) e Krainski et al. (2016). Todas as análises foram realizadas utilizando a linguagem R.4.3.2 (R CORE TEAM, 2023).

DADOS: Foram coletadas 36 amostras de solo de um talhão de aproximadamente 185 hectares de uma fazenda localizada em Tangará da Serra, Mato Grosso. Para cada amostra, foram mensuradas 39 características químicas e físicas, o qual, para este estudo, foram consideradas 10 variáveis classificadas como essenciais para o desenvolvimento de plantas, são elas:

? Potássio (K): essencial para a regulação da abertura e fechamento dos estômatos, transporte de nutrientes, síntese de proteínas e ativação de enzimas. Pode afetar a absorção de magnésio e cálcio pelas plantas.

? Cálcio (Ca): componente estrutural das paredes celulares, ativação de enzimas, regulação do crescimento das raízes. Pode competir com o magnésio na absorção pelas raízes.

? Magnésio (Mg): componente central da clorofila, envolvido na fotossíntese e ativação de enzimas. Pode ser afetado pela presença excessiva de potássio ou cálcio no solo.

? Enxofre (S): essencial para a síntese de proteínas, aminoácidos e vitaminas. Pode ser influenciado pela disponibilidade de outros nutrientes, como nitrogênio.

? Fósforo (P): importante para a síntese de DNA, RNA, ATP e outros compostos energéticos. A presença de íons de ferro e alumínio pode afetar sua disponibilidade no solo.

? Ferro (Fe): essencial para a formação da clorofila e transporte de elétrons na fotossíntese. O pH do solo pode afetar sua disponibilidade.

? Manganês (Mn): atua como cofator de enzimas envolvidas na fotossíntese e na decomposição de compostos orgânicos. A disponibilidade é influenciada pelo pH do solo.

? Zinco (Zn): participa da ativação de enzimas e no metabolismo de carboidratos. Pode ser afetado pela presença excessiva de fósforo.

? Boro (B): Importante para a formação da parede celular, transporte de açúcares e síntese de nucleotídeos. O excesso de cálcio pode reduzir a absorção de boro.

? Cobre (Cu): participa em processos metabólicos, como a síntese de lignina e a ativação de enzimas. O excesso de fósforo pode reduzir a absorção de cobre.

A interação entre esses elementos é complexa, e o equilíbrio nutricional no solo é crucial para otimizar o desenvolvimento das plantas. Uma deficiência ou excesso de qualquer um desses nutrientes pode resultar em problemas de crescimento, redução na produção e susceptibilidade a doenças. A variável de interesse é a saturação de bases trocáveis (V%). Esse índice fornece informações sobre a capacidade do solo em reter nutrientes essenciais para as plantas e está relacionado com a quantidade de íons de bases trocáveis presentes nos sítios de troca do solo. As bases trocáveis principais incluem cálcio ($Ca^{2?}$), magnésio ($Mg^{2?}$), potássio ($K^{?}$) e sódio ($Na^{?}$). A fórmula para calcular a saturação de bases trocáveis (V%) é:

$$V\% = \left(\frac{Soma\ das\ bases\ trocáveis\ (cmolc/kg)}{Capacidade\ de\ troca\ de\ cátions\ (cmolc/kg)}\right) \times 100$$

Essa fórmula expressa a porcentagem de saturação das bases trocáveis em relação à capacidade de troca de cátions do solo. A capacidade de troca de cátions representa a capacidade do solo em reter íons positivos (cátions) e é um indicador da fertilidade do solo. A interpretação da saturação de bases trocáveis pode variar dependendo do tipo de solo e das culturas a serem cultivadas, mas algumas orientações gerais incluem:

? Saturação adequada (ideal): valores geralmente desejáveis para V% variam entre 50% e 70%. Isso sugere um equilíbrio saudável entre cálcio, magnésio, potássio e outros cátions, proporcionando um ambiente propício para o desenvolvimento das plantas.

? Saturação baixa (deficiente): valores abaixo de 50% podem indicar deficiências de cálcio e/ou magnésio. Nesse caso, pode ser necessário corrigir a acidez do solo e fornecer suplementos desses nutrientes.

? Saturação alta (excesso): valores acima de 70% podem indicar excesso de cálcio ou magnésio em relação aos outros cátions. Isso pode interferir na absorção de outros nutrientes pelas plantas e, em alguns casos, exigir correções para equilibrar os íons presentes.

RESULTADOS E DISCUSSÃO

As estatísticas descritivas das propriedades do solo estão apresentadas na Tabela 1. A saturação de bases trocáveis (V%) possui média acima de 70% (72,7 ± 6,85) indicando que a área possa apresentar excesso de cálcio (Ca) e magnésio (Mg). Entretanto, foi observado que os valores médios e desvios-padrões para Ca e Mg indicam um teor bom para esses macronutrientes. Potássio (K) foi o macronutriente com maior coeficiente de variabilidade. Para os micronutrientes, apenas boro (B) e fósforo (P) apresentaram teor médio, embora P tenha alto coeficiente de variação (67,5%). Foram encontrados elevados teores médios para enxofre (S), cobre (Cu), ferro (Fe), magnésio (Mn) e zinco (Zn), sendo destes apenas o Cu e Fe com alta dispersão.

Tabela 1: Medidas descritivas para as variáveis químicas do solo.

	Unidade	**Média**	**DP**	**CV**	**Mediana**	**Min**	**Máx**	**Assimetria**	**Curtose**	**Classificação**
V%	%	72,70	6,85	9,42	73,15	57,26	86,51	-0,14	-0,19	Alto
Macronutrientes										
K	$cmolc/dm^3$	0,16	0,07	41,51	0,15	0,09	0,40	1,17	1,61	Médio
Ca	$cmolc/dm^3$	3,11	0,51	16,46	3,13	2,32	4,04	0,16	-1,39	Bom

	Unidade	Média	DP	CV	Mediana	Min	Máx	Assimetria	Curtose	Classificação
Mg	cmolc/dm^3	1,22	0,29	23,48	1,19	0,59	1,84	0,38	-0,33	Bom
Micronutrientes										
S	ppm	11,46	1,23	10,73	11,33	9,63	15,42	1,19	1,30	Alto
B	ppm	0,39	0,05	11,96	0,38	0,29	0,47	-0,11	-0,94	Médio
Cu	ppm	1,16	0,44	37,87	1,10	0,50	2,30	0,78	0,09	Alto
Fe	ppm	84,10	8,92	10,61	81,55	70,00	107,10	0,62	-0,51	Alto
Mn	ppm	15,47	2,12	13,69	15,43	10,78	20,51	-0,15	0,36	Alto
Zn	ppm	6,50	1,82	28,02	6,35	3,30	13,00	1,14	2,71	Alto
P	ppm	19,48	13,15	67,50	13,73	3,04	51,80	1,04	0,00	Médio

*Fonte: Adaptado Comissão de Fertilidade do Solo do Estado de Minas Gerais. 5ª (1999); Centro de pesquisa e Desenvolvimento de Solos e Recursos Ambientais

Conforme os resultados apresentados na Tabela 2, ao nível de 95% de confiança, temos que as correlações positivas fortes para Ca e Mg; e Cu e Zn moderada para V% e Mg; fraca para V% e Ca; Zn e Mn; Zn e P; e Ca e Mn. As correlações negativas foram todas referentes ao fósforo e as magnitudes das correlações foram moderadas, são elas: Fe, K, Mg e Ca. Assim, para as correlações positivas, espera-se que o aumento em um desses elementos esteja correlacionado com o aumento no seu outro par significativo, enquanto para as correlações negativas, o aumento de um elemento está correlacionado à diminuição no seu outro par.

Tabela 2: Correlação de Pearson para as variáveis químicas do solo.

	V%	K	Ca	Mg	S	B	Cu	Fe	Mn	Zn	P
V%	1,00										
K	-0,21	1,00									
Ca	0,43*	0,30	1,00								
Mg	0,62*	0,15	0,73*	1,00							
S	0,08	-0,18	-0,10	-0,06	1,00						
B	0,03	0,20	-0,08	-0,03	-0,22	1,00					
Cu	-0,32	-0,04	0,07	-0,05	0,03	0,00	1,00				
Fe	-0,31	0,21	0,22	0,28	-0,21	-0,04	0,10	1,00			
Mn	0,25	0,26	0,46*	0,25	-0,01	0,21	0,27	-0,14	1,00		
Zn	0,02	-0,09	0,22	-0,02	0,14	-0,14	0,70	-0,32	0,38*	1,00	
P	0,13	-0,45*	-0,37*	-0,40*	0,28	-0,07	0,18	-0,67*	0,17	0,42*	1,00

*Significativo ao nível de 5%

A figura 1 apresenta a distribuição espacial para a interpolação via krigagem dos elementos essenciais K, Ca, Mg, S, B, Cu, Fe, Mn, Zn e P. Nota-se que para os pares de elementos positivamente correlacionados, a distribuição espacial é semelhante, do modo contrário, para os pares de elementos que apresentam correlação negativa, a presença de um elemento, reflete na baixa presença do seu outro par. Para os pares de nutrientes positivamente correlacionados, temos:

? Ca e Mg: embora o excesso de Ca possa levar a deficiência de Mg, temos que a relação Ca/Mg chegou a 4,35, pouco acima do máximo indicado (4);

? Cu e Zn: o excesso de Zn pode reduzir a absorção de Cu. Nas amostras foram observados uma relação de Cu/Zn máxima de 0,35, indicando maior presença de Zn;

? V% e Mg: Níveis baixos de Mg em solos com alto V% podem propiciar lixiviação e contribuir para o aumento da acidez;

? V% e Ca: o baixo teor de Ca em solos com alto V% podem acusar desequilíbrio de nutrientes, aumentar a acidez e diminuir a atividade microbiana;

? Zn e Mn: o excesso de Zn pode reduzir a absorção de Mn. A relação máxima de Zn/Mn foi de 0,84, embora algumas amostras apresentaram uma relação de aproximadamente 0,25, indicando desequilíbrio entre os elementos;

? Zn e P: o excesso de P pode reduzir a absorção de Zn, além disso, níveis baixos de Zn podem ser um problema em solos com alto teor de P, pois podem causar um desequilíbrio nutricional, afetando a saúde das plantas. Segundo as amostras coletadas, a relação Zn/P média foi de 0,41, embora algumas amostras indiquem áreas 1:1.

? Ca e Mn: a presença de Ca pode reduzir a absorção de Mn pelas plantas. A relação máxima de Ca/Mn foi de 0,32.

Para os pares de nutrientes negativamente correlacionados, temos:

? P e Fe: altos níveis de P no solo podem levar à deficiência de Fe, principalmente em solos calcários. A deficiência de Fe pode causar clorose (amarelecimento das folhas), redução do crescimento das plantas e menor produção. A proporção P/Fe média foi de 0,24, variando de 0,03 a 0,71.

? P e K: altos níveis de P no solo podem levar à deficiência de K, principalmente em solos arenosos. A deficiência de K pode causar amarelecimento das folhas, murcha e menor produção.

? P e Mg: Altos níveis de P no solo podem levar à deficiência de Mg, principalmente em solos ácidos. A deficiência de Mg pode causar amarelecimento das folhas, queda prematura das folhas e menor produção.

? P e Ca: Altos níveis de P no solo podem levar à deficiência de Ca, principalmente em solos ácidos. A deficiência de Ca pode causar fraqueza das plantas, morte das raízes e menor produção. A relação P/Ca média foi de 6,7, variando de 1,31a 20,63.

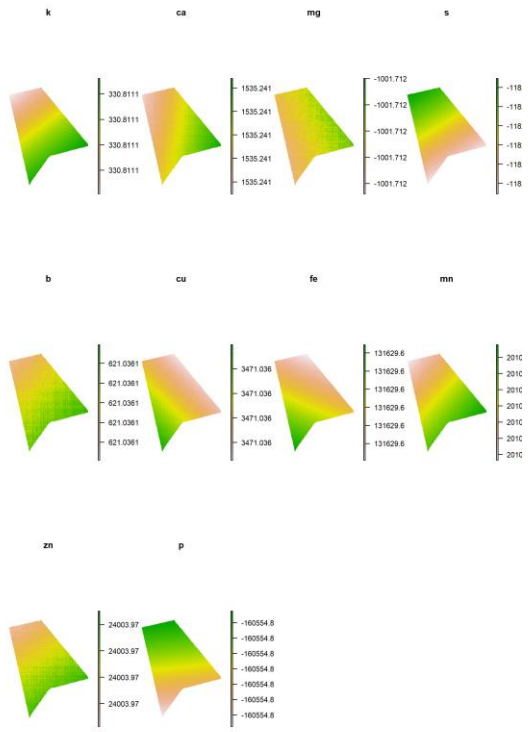


Figura 1: Distribuição espacial das covariáveis - K, Ca, Mg, S, B, Cu, Fe, Mn, Zn, e P.

Para construção de um modelo geoestatístico usando o INLA é necessário definir a estrutura de correlação espacial para a parte SPDE do modelo (Lindgren e Rue, 2015). Assim, foram consideradas as localizações dos pontos amostrais para a criação de uma malha de estrutura triangular. A Figura 2 apresenta a) o mapa do talhão com os pontos amostrais, b) a estrutura de correlação espacial formada por 147 triângulos e 87 vértices e c) a sobreposição da malha no talhão. Os números de triângulos e vértices foram definidos empiricamente para que os triângulos fossem mais similares possíveis.

CONCLUSÃO

A interpolação da saturação de bases trocáveis (V%) é importante para auxiliar os responsáveis técnicos e os demais profissionais responsáveis pelo plantio de uma cultura. Devido ao efeito da interação entre os elementos químicos presentes no solo, à sua dinâmica complexa, e métodos tradicionais como krigagem podem não apresentar bons ajustes. Nesse sentido, este trabalho utilizou uma abordagem bayesiana para ajuste de um modelo geoestatístico. Essa metodologia foi implementada através do Integrated Nested Laplace Approximation com equação diferencial parcial estocástica (INLA-SPDE), disponível no software R, obtendo-se assim as interpolações para a variável de interesse, bem como as estimações para os efeitos fixos das variáveis essenciais que foram incorporadas no modelo. De acordo com a divergência de Kullback-Leibler (KLD), o modelo possui excelente concordância entre a distribuição a posteriori verdadeira e a aproximação do INLA, produzindo estimações adequadas para a saturação de bases trocáveis (V%). Em outras palavras, este modelo se mostrou apropriado para capturar características espacialmente distribuídas da saturação de bases trocáveis (V%) e a relação entre as variáveis essenciais K, Ca, Mg, S, B, Cu, Fe, Mn, Zn e P. Vale ressaltar que a krigagem continua sendo um método viável devido a sua fácil construção, visto que muitos softwares apresentam esse método como padrão e na sua maioria, não requer conhecimentos mais avançados de programação e estatística.

REFERÊNCIAS

BASTOS, M. M. Modelagem Probabilística da Dinâmica da Zika usando Modelos Hierárquicos Bayesianos. Tese (PhD dissertation) - FGV/Emap, 2018.

BLANGIARDO, M., CAMELETTI, M., BAIO, G., RUE, H. Spatial and spatio-temporal models with R-INLA. Spat. Spatiotemporal Epidemiol. 7, 39-55. 2013.

CAMELETTI, M., FINN L., SIMPSON, D., RUE, H. "Spatio-Temporal Modeling of Particulate Matter Concentration Through the SPDE Approach." AStA Advances in Statistical Analysis 97 (2): 109-31. https://doi.org/10.1007/s10182-012-0196-3. 2013.

DALCHIAVON, F. C. Variabilidade espacial de atributos químicos do solo cultivado com soja sob plantio direto. Revista de Ciências Agroveterinárias, v. 16, n. 2, p. 144-154, 2017.

HAGAN, J. E., MORAGA, P., COSTA, F., CAPIAN, N., RIBEIRO, G. S., WUNDER JR., RIDALVA FELZEMBURGH, D. M. "Spatio-temporal determinants of urban leptospirosis transmission: Four-year prospective cohort study of slum residents in Brazil." Public Library of Science: Neglected Tropical Diseases 10 (1): e0004275. https://doi.org/10.1371/journal.pntd.0004275. 2016

KRAINSKI, E.T., LINDGREN, F., SIMPSON, D., RUE, H., The R-INLA Tutorial on SPDE Models. Available from. https://www.math.ntnu.no/inla/r-inla.org/tutorials/spde/spde-tutorial.pdf. 2016.

KNORR-HELD, L. Bayesian Modelling Of Inseparable Space-Time Variation In Disease Risk. Statistics In Medicine, Wiley Online Library, v. 19, n. 17-18, p. 2555-2567, 2000.

MORAGA, P., CHRISTOPHER D., JOSHUA I., PIOTR M., SHAHZEB R. N., FENGPEI W. "Bayesian spatial modelling of geostatistical data using INLA and SPDE methods: A case study predicting malaria risk in Mozambique." Spatial and Spatio-Temporal Epidemiology 39: 100440. https://doi.org/10.1016/j.sste.2021.100440. 2021.

MARTINS, I.F., TEIXEIRA, A.L., PINHEIRO, L., FALCAO, A.O., A Bayesian approach to in silico blood-brain barrier penetration modeling. J. Chem. Inf. Model. 52, 1686-1697. 2012.

MCBRATNEY, A.B., On variation, uncertainty and informatics in environmental soil management. Soil Res. 30, 913-935. 1992.

POGGIO, L., GIMONA, A., SPEZIA, L., & BREWER, M. J. Bayesian spatial modelling of soil properties and their uncertainty: The example of soil organic matter in Scotland using R-INLA. Geoderma, 277, 69-82. 2016.

R CORE TEAM. R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna, Austria. <https://www.R-project.org/>. 2023.

RUE, H.; MARTINO, S. Approximate Bayesian Inference for Hierarchical Gaussian Markov Random Field Models. Journal of statistical planning and inference, Elsevier, v. 137, n. 10, p. 3177-3192, 2007.

RUE, H.; MARTINO, S.; CHOPIN, N. Approximate Bayesian Inference for Latent Gaussian Models by Using Integrated Nested Laplace Approximations. Journal of the royal statistical society: Series B (statistical methodology), Wiley Online Library, v. 71, n. 2, p. 319-392, 2009.

PREDIÇÃO DA PRODUTIVIDADE DA BANANEIRA UTILIZANDO VARIÁVEIS DE SOLO, PLANTA E ÍNDICES DE VEGETAÇÃO EM URABÁ, COLÔMBIA.

Laura Delgado Bejarano [1]; Darío Castañeda Sanchez [2]; Juan José Pérez Zapata [3]; Sebastián Zapata Henao [4]; Lucas Rios do Amaral [5]

[1]Eng. Agrícola, Mestrando. Av. Cândido Rondon, 501 - Barão Geraldo 13083-875 - Campinas/SP.. FEAGRI Universidade Estadual de Campinas, UNICAMP; [2]Eng. Agrônomo, Professor Associado. Calle 59A # 63 - 20; Medellín, Colômbia. Universidad Nacional de Colombia - Grupo de pesquisa Fitotecnica Trópical; [3]Eng. Agrônomo, Pesquisador Solos e agricultura de precisão. km 4 Carepa- Apartadó, Colômbia. Centro de investigaciones del banano (Cenibanano); [4]Eng. Agropecuário, Diretor . km 4 Carepa- Apartadó, Colômbia. Centro de investigaciones del banano (Cenibanano); [5]Eng. Agrônomo, Professor Associado. Av. Cândido Rondon, 501 - Barão Geraldo 13083-875 - Campinas/SP.. FEAGRI Universidade Estadual de Campinas, UNICAMP

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

No cultivo da banana, a implementação de agricultura de precisão é desafiadora pelo assincronismo da cultura, na maioria dos casos, as decisões são baseadas em dados de colheita o que dificulta a tomada de decisões e análises econômicas no momento oportuno. Assim, neste estudo avaliamos se a inclusão de variáveis de solo e sensoriamento remoto nos modelos de predição da massa do cacho de banana (*Musa* AAA) melhora a qualidade das estimativas. Para isso, área produtivas em Urabá, Colômbia, foram utilizadas para a coleta de dados. Modelos de regressão linear com diferentes tipos de seleção de variáveis foram utilizados para avaliar a melhor combinação de variáveis para a predição da massa do cacho. O melhor desempenho foi observado com uma seleção do tipo "backward" (MAIC) (R^2=0,73), mas foi encontrado que a seleção por correlação (MC) apresenta métricas semelhantes com menos variáveis (R^2=0,72). Com isso, a predição da produtividade da banana é possível de ser realizada cerca de 80 dias antes da colheita, o que pode otimizar as práticas agrícolas realizadas pelo produtor.

PALAVRAS-CHAVE: Regressão múltipla; modelos de predição; *Musa* AAA

ABSTRACT

In banana cultivation, the implementation of precision agriculture is challenging due to the asynchrony of the crop; in most cases, decisions are based on harvest data, which complicates timely decision-making and economic analyses. Thus, in this study, we evaluated whether the inclusion of soil variables and remote sensing in banana bunch mass prediction models (Musa AAA) enhances the quality of estimates. For this purpose, productive areas in Urabá, Colombia, were used for data collection. Linear regression models with different variable selection techniques were employed to assess the best combination of variables for bunch mass prediction. The best performance was observed with a "backward" selection approach (MAIC) (R^2=0.73), but it was found that correlation-based selection (MC) yields similar metrics with fewer variables (R^2=0.72). Consequently, banana productivity prediction can be made approximately 80 days before harvest, potentially optimizing agricultural practices for producers.

KEYWORDS: covariáveis;

INTRODUÇÃO

A banana (*Musa* AAA) é amplamente consumida globalmente. No entanto, as mudanças climáticas e o aumento dos custos de produção têm reduzido sua produtividade e exportações. Surge então a

agricultura de precisão (AP) como uma solução, utilizando ferramentas, tecnologia e informações para melhorar a tomada de decisões no campo e aumentar os rendimentos de forma eficiente, maximizando os benefícios ambientais(SHAFI et al., 2019).

Atualmente, diferentes técnicas de AP são utilizadas em várias culturas para gerar mapas de gestão e analisar a produtividade, como é o caso da soja e da cana-de-açúcar, onde modelos de previsão de produtividade são feitos com base em imagens de satélite e drones (DIMOV et al. 2022; MAIMAITIJIANG et al. 2020). No entanto, no caso da banana, sua aplicação é dificultada pelo assincronismo do cultivo, o que implica em diferentes estados fenológicos dentro da mesma área. Essa situação dificulta a tomada de decisões e análises econômicas futuras, sendo necessário realizar análises baseadas em dados durante a colheita, como massa do cacho, folhas no momento da colheita, grossura e comprimento dos frutos etc. (LAMOUR et al. 2020).

Com base nisso, diversos autores buscam desenvolver modelos para estimar a produtividade do cultivo de banana com base em diferentes parâmetros morfológicos e externos que podem ser coletados de forma precoce antes da colheita, como evidenciado na pesquisa apresentada por CASTAÑEDA et al. (2014). Esses autores desenvolveram modelos de regressão a partir de parâmetros do solo, compreendendo o comportamento espacial da produção e as variáveis mais significativas para a tomada de decisões de manejo específico. Similarmente, OLIVARES et al. (2020) apresentaram um modelo de regressão para determinar o efeito das propriedades do solo sobre as variáveis produtivas do cultivo e encontraram baixa relação. No entanto, embora o sensoriamento remoto seja usado para prever produtividade em alguns cultivos, seu uso combinado com propriedades do solo nas previsões para bananas ainda é pouco explorado. Geralmente, os estudos em banana se concentram nas características morfológicas da planta ou, em alguns casos, nas propriedades do solo. Assim, a integração dessas variáveis pode ser uma alternativa para melhorar as predições.

OBJETIVOS

O objetivo desta pesquisa consistiu em avaliar se a integração de parâmetros do solo e de sensoriamento remoto com as variáveis morfológicas da planta permitem melhorar a precisão dos modelos de produtividade do cultivo de banana na região de Urabá, Colômbia.

MATERIAL E MÉTODOS

Neste estudo, foram selecionadas três fazendas comerciais dedicadas à exportação de banana, localizadas nos municípios de Carepa e Turbo, em Antioquia, Colômbia. Essas fazendas apresentam precipitação média anual entre 2654 e 3301 mm e temperatura média anual de 27,5°C. Foram selecionados lotes de cada fazenda com o mesmo manejo, idade de plantio, isentos de problemas fitossanitários e mesmo clone de banana (*Musa* AAA Cavendish cv. Williams) para garantir uma maior homogeneidade; em cada lote, foram selecionadas três subáreas de 0,40 ha cada (Figura 1).

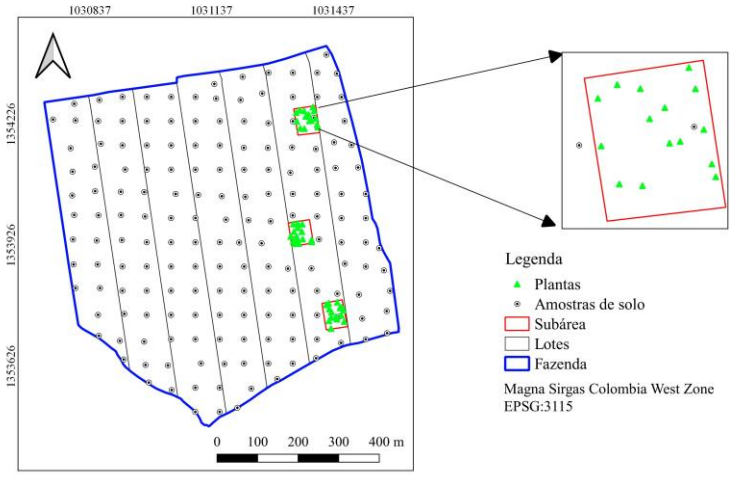


Figura 1. Exemplo de uma das fazendas de estudo, mostrando como os lotes costumam ser distribuídos e indicando as subáreas e plantas analisadas, assim como os pontos de coleta de solo.

O solo das três fazendas foi amostrado em uma densidade de três pontos por hectare, separados aproximadamente 57 metros ente si (Figura 1). Foram coletadas amostras de solo na planta mais próxima e a 50 cm de distância entre a planta mãe e seu filho sucessor, evitando assim a zona de fertilização. Cada amostra consistiu em uma trincheira de 30x30 cm, sendo que 500 g de solo foi encaminhado para análise de pH e textura em laboratório. A resistência à penetração foi medida com um penetrômetro digital (Eijkelkamp) no mesmo intervalo de distância da unidade produtiva (planta mãe) e a uma profundidade de 0 a 80 cm, imediatamente ao lado da trincheira aberta. O equipamento possui uma sonda volumétrica de umidade com a qual foram registrados os dados em cada um dos pontos de amostragem.

Utilizando um drone DJI Mavic Mini 2 equipado com câmera RGB, foram capturadas imagens com uma velocidade de 3,6 km/h e uma altura de voo de 20 m. As imagens foram capturadas com uma sobreposição lateral de 80% e frontal de 75%. A partir das imagens, foram preparados mosaicos para cada subárea em avaliação, resultando em GSD médio de 0,81 cm²/px (0,9 x 0,9 cm). Os voos foram realizados no mesmo dia dos levantamentos de solo em cada um dos lotes. A partir das bandas RGB dos mosaicos, foram obtidos os índices de vegetação apresentados nas equações 1 a 4, os quais foram posteriormente extraídos através de um polígono do dossel de cada planta, delimitado visualmente e, então, extraído o valor médio por planta. Os índices foram: Índice modificado de reflectância fotoquímica (MPRI), Índice de verdor triangular (TGI), Índice de resistência atmosférica visível (VARI), Índice de excesso de verde (EXG) (STARÝ et al. 2020).

MPRI = G-R/G+R (1)

TGI = G-0,39*R-0,61*B (2)

VARI = R-G/G+R-B (3)

EXG = 2*g-r-b (4) onde,

r = (R/255)/((R/255) +(G/255)+(B/255)) (5);

g = (G/255)/((R/255)+(G/255)+(B/255)) (6);

b = (B/255)/((R/255)+(G/255)+(B/255)) (7)

Em cada subárea, foram referenciadas com GPS e etiquetadas 15 plantas em estágio de floração, com a inflorescência totalmente emitida. Em cada planta mãe, foram contadas as folhas funcionais (F) e a circunferência do pseudocaule a 1 m de altura (P), número de "mãos" (M) e número total de dedos (D). Uma vez que os cachos atingiram a maturidade de colheita (11 semanas depois), foram colhidos e transportados para a empacotadora, onde foi determinado a massa do cacho (PBC, em kg). No total, foram avaliadas 135 plantas durante o estudo.

Os dados de solo (pH, textura e resistência a penetração) foram interpolados por Multilevel B-Spline. Esses parâmetros e os índices de vegetação foram associados às coordenadas das plantas amostradas e, por meio de uma análise estatística de zona, foi obtido o valor médio de cada um dos índices para cada uma das plantas.

Posteriormente, utilizou-se o software R para análise estatística e geração de modelos de regressão. Os modelos utilizados foram: 1. Regressão linear com base apenas nas variáveis morfológicas da cultura (folhas, perímetro pseudocaule, mãos e dedos totais) (MP); 2. Regressão linear múltipla com todas as variáveis de planta, solo e sensoriamento (ML); 3. Regressão linear múltipla com seleção de variáveis pelo método "backward", usando o critério de informação de Akaike como otimizador (MAIC); e 4. Regressão linear múltipla usando apenas os parâmetros que demostraram correlação com o PBC (MC); e 5. Regressão linear múltipla usando apenas parâmetros de solo e sensoriamento remoto (MSS). Por último, foram utilizados o coeficiente de determinação ajustado (R^2), erro absoluto médio (MAE) e o erro médio quadrático (RMSE) para avaliar a precisão dos modelos na estimativa do PBC.

RESULTADOS E DISCUSSÃO

Os valores de R^2 para os modelos variaram entre 41,85 % e 73,26% (Tabela 2), com o pior desempenho sendo apresentado pelo modelo MSS, seguido pelo MP. Esse baixo desempenho preditivo está de acordo com os achados de ZUCOLOTO et al. (2013) em seu estudo realizado no Brasil com banana Prata Anã, onde, por meio de uma regressão linear com quatro variáveis de planta (diâmetro do cacho, comprimento da terceira folha, número de folhas no momento da colheita e total de bananas por cacho), estimaram a massa do cacho com um R^2 de 58%. No entanto, as variáveis usadas exigem uma medição manual laboriosa e, além disso, devem ser realizadas o mais próximo no momento da colheita possível, tornando-as impraticáveis para uma estimativa oportuna na tomada de decisões.

A inclusão das variáveis de solo e de sensoriamento auxiliaram na predição da massa dos cachos das bananeiras. O modelo MAIC apresentou os melhores resultados e 9 variáveis: número de folhas em floração (F), Resistência à penetração de 30 a 60 cm de profundidade (R_{3060}), conteúdo de umidade volumétrica superficial (W), índice de resistência atmosférica visível (VARI), índice modificado de reflectância fotoquímica (MPRI), índice de verdor triangular (TGI), índice de excesso de verde (EXG), mãos (M) e dedos totais (D). No entanto, o modelo MC com sete variáveis apresenta um ajuste similar, permitindo a redução do número de parâmetros, considerando: o perímetro do pseudocaule a 1 m de altura (P), mãos (M), dedos totais (D), resistência à penetração nos estratos de 30-60 cm e 60-80 cm (R_{3060}, R_{6080}), teor de silte (S) e o índice de resistência atmosférica visível (VARI). Este processo é semelhante ao realizado por OLIVARES et al. (2020) onde selecionaram um modelo com menos variáveis e um ajuste mais baixo em seu estudo sobre banana Cavendish. Neste estudo, os autores mencionam que, embora o valor de R^2 seja menor, o uso de menos variáveis para a previsão da produtividade permite que o modelo seja mais facilmente aplicável pelos agricultores. Vale ressaltar que as variáveis foram coletadas 11 semanas antes da colheita, o que resulta em tempo considerável para a tomada de decisões em áreas de baixa produtividade ainda durante a safra, além de permitir uma previsão financeira antes do período da colheita (SOARES et al. 2014). No entanto, não é suficiente usar apenas variáveis de solo e sensoriamento remoto; as

variáveis morfológicas também são necessárias para um bom desempenho do modelo, como evidenciado pelos resultados do modelo MSS.

Tabela 2. Métricas de desempenho dos modelos de predição de peso do cacho**.**

Modelo	R^2 (%)	MAE (kg)	RMSE (kg)	N° de variáveis
MP	55,56	2,95	3,75	4
ML	65,32	2,72	3,28	15
MAIC	73,26	2,37	2,93	9
MC	72,39	2,51	2,98	7
MSS	41,85	3,50	4,30	11

Para visualizar o comportamento espacial das previsões, na Figura 2 é ilustrado o mapa de massa do cacho para cada um dos modelos avaliados e do PBC avaliado diretamente no campo para uma das subáreas avaliadas, todos os mapas foram gerados a partir dos pontos amostrais coletados em campo seguido por uma interpolação Multilevel B-Spline. Os modelos que incorporam variáveis de solo e sensoriamento remoto mostram uma tendência semelhante nos resultados, com variações suavizadas, possivelmente devido às diferentes variáveis usadas em cada modelo. No entanto, o modelo MP apresenta um comportamento espacial diferente, com valores mais altos de massa de cacho observados na zona central. É interessante observar essas diferenças, pois esperava-se que o modelo MP apresentasse bons resultados, uma vez que inclui as variáveis morfológicas comumente usadas nas fazendas de banana para a estimativa de produtividade (ZUCOLOTO et al. 2013). Além disso, espacialmente observa-se que o modelo MSS não representa adequadamente a produtividade, já que ocorre uma superestimação da massa do cacho de forma geral na subárea de avaliação. No entanto, esses modelos apresentam as métricas mais baixas na regressão e um comportamento espacial contrastante com a referência, o que destaca a influência dos parâmetros externos à planta na produtividade do cultivo e demonstra a importância de incluir outras variáveis, como propriedades do solo e relacionadas ao desenvolvimento do dossel da cultura medida por sensoriamento remoto, sem deixar de considerar as variáveis morfológicas.

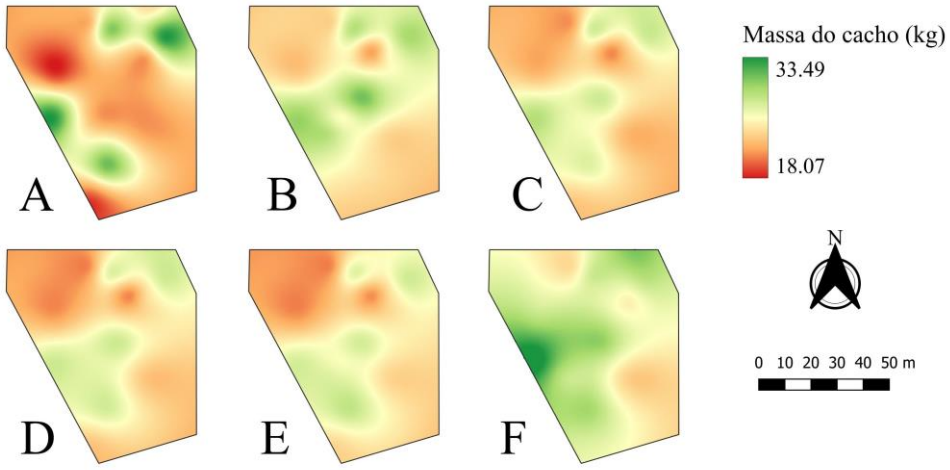


Figura 2. Variabilidade espacial da massa do cacho a partir de cada um dos modelos testados. A: PBC (referência); B: MP; C: ML; D: MAIC; E: MC; F:MSS

CONCLUSÃO

A adição de variáveis de solo e sensoriamento remoto aos modelos lineares para prever a massa do cacho melhora o desempenho dos modelos preditivos. O modelo de regressão linear múltipla com seleção de variáveis correlacionadas (MC) é mais parcimonioso que os demais, atingindo boa precisão e uma tendência espacial consistente com os valores observados em campo, mesmo utilizando menos variáveis. Essa abordagem permite que os agricultores estimem a produtividade 11 semanas antes da colheita, facilitando projeções financeiras e tomadas de decisão.

AGRADECIMENTOS

Enaltecemos o apoio da FAPESP nesta e em outras pesquisas do grupo, projeto n° 2022/03160-8.

REFERÊNCIAS

CASTAÑEDA, D.; JARAMILLO, D.; COTES, J. Selección de propiedades del suelo espacialmente relacionadas con producción en el cultivo de banano. **Ciencia Del Suelo**, v. 32, n. 1, p. 73-83, 2014.

DIMOV, D.; UHL, J. H.; LÖW, F.; SEBOKA, G. N. Sugarcane yield estimation through remote sensing time series and phenology metrics. **Smart Agricultural Technology**, v. 2, n. December 2021, p. 100046, 2022. Disponível em: <https://doi.org/10.1016/j.atech.2022.100046>.

LAMOUR, J.; NAUD, O.; LECHAUDEL, M.; LE MOGUÉDEC, G.; TAYLOR, J.; TISSEYRE, B. Spatial analysis and mapping of banana crop properties: issues of the asynchronicity of the banana production and proposition of a statistical method to take it into account. **Precision Agriculture**, v. 21, n. 4, p. 897-921, 2020. Disponível em: <https://doi.org/10.1007/s11119-019-09700-7>.

MAIMAITIJIANG, M.; SAGAN, V.; SIDIKE, P.; HARTLING, S.; ESPOSITO, F.; FRITSCHI, F. B. Soybean yield prediction from UAV using multimodal data fusion and deep learning. **Remote Sensing of Environment**, v. 237, n. May 2019, p. 111599, 2020. Disponível em: <https://doi.org/10.1016/j.rse.2019.111599>.

OLIVARES, B. O.; ARAYA-ALMAN, M.; ACEVEDO-OPAZO, C.; REY, J. C.; CAÑETE-SALINAS, P.; KURINA, F. G.; BALZARINI, M.; LOBO, D.; NAVAS-CORTÉS, J. A.; LANDA, B. B.; GÓMEZ, J. A. Relationship Between Soil Properties and Banana Productivity in the Two Main Cultivation Areas in Venezuela. **Journal of Soil Science and Plant Nutrition**, v. 20, n. 4, p. 2512-2524, 2020.

SOARES, J. D. R.; PASQUAL, M.; LACERDA, W. S.; SILVA, S. O.; DONATO, S. L. R. Comparison of techniques used in the prediction of yield in banana plants. **Scientia Horticulturae**, v. 167, p. 84-90, 2014.

STARÝ, K.; JELÍNEK, Z.; KUMHÁLOVA, J.; CHYBA, J.; BALÁ?OVÁ, K. Comparing RGB-based vegetation indices from UAV imageries to estimate hops canopy area. **Agronomy Research**, v. 18, n. 4, p. 2592-2601, 2020.

ZUCOLOTO, M.; LIMA, J. S. de S.; COELHO, R. I.; XAVIER, A. C. Modelos de regressão para estimação da massa do cacho de bananeira cv. Prata Anã. **Bioscience Journal**, v. 29, n. 6, p. 1997-2000, 2013.

ZONEAMENTO DE VINHEDO PARA MANEJO DE NUTRIÇÃO E COLHEITA UTILIZANDO APRENDIZADO DE MÁQUINA

CAIO BUSTANI ANDRADE [1]; DANIEL ALEXANDRE HEBERLE [2]; MATHEUS SOUSA SILVA [3]; CRISTIAN SOLDI [5]; ALEXANDRE TEN CATEN [5]

[1]Bolsista de Pós-Mestrado. Curitibanos - SC, Brasil. Universidade Federal de Santa Catarina; [2]Bolsista de Pós-Doutorado. Curitibanos - SC, Brasil. Universidade Federal de Santa Catarina; [3]Mestrando do PPG Ecossistemas Agrícolas e Naturais. Curitibanos - SC, Brasil. Universidade Federal de Santa Catarina; [4]Graduando em Agronomia. Curitibanos - SC, Brasil. Universidade Federal de Santa Catarina; [5]Professor. Curitibanos - SC, Brasil. Universidade Federal de Santa Catarina

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A produção de vinhos finos requer que as videiras sejam devidamente nutridas e produzam frutos com propriedades favoráveis à vinificação. Além das características próprias das cultivares, o desempenho das videiras é fortemente influenciado por fatores ambientais como solo e clima. Estes fatores de distribuem de forma desigual no campo e sua interação cria condições específicas para o desenvolvimento vegetal. A Viticultura de precisão procura explicitar esta heterogeneidade, permitindo ajustes que resultem em colheitas mais rentáveis. A análise de agrupamento é um método estatístico para processamento de dados que organiza objetos ou indivíduos em grupos com base no grau de semelhança entre as suas características ou comportamentos. Neste estudo, indicadores de nutrição das plantas e de maturação dos frutos foram utilizados para criar zonas de manejo em um vinhedo, empregando o algoritmo de Particionamento em Torno dos Medoides, uma técnica de aprendizado de máquina não supervisionado. O estudo foi realizado no município de Curitibanos, Santa Catarina, sul do Brasil, em um talhão do vinhedo composto por plantas da cultivar Sauvignon Blanc com 4 anos de idade (n = 57). O zoneamento utilizando parâmetros de nutrição das videiras apresentou forte dependência espacial, intimamente associada ao relevo, ao passo que o zoneamento utilizando parâmetros de maturação dos frutos resultou em um mosaico mais diversificado, suscitando maior investigação devido aos possíveis efeitos do microclima na fisiologia das plantas. Os resultados explicitam as propriedades que definiram cada uma das zonas e indicam a viabilidade no uso da ferramenta para intervenções no manejo e gestão.

PALAVRAS-CHAVE: viticultura; mineração de dados; k-medoides

ABSTRACT

The production of high-quality wines requires that the vines are properly nourished and yield fruits with properties that are favorable to winemaking. In addition to the cutivars' own characteristics, the performance of the vines is strongly influenced by environmental factors such as soil and climate. These factors are unevenly distributed in the field and their interaction creates specific conditions for grapevine development. Precision viticulture seeks to make this heterogeneity explicit, allowing for adjustments that result in more profitable harvests. Cluster analysis is a statistical method for processing data that organizes objects or individuals into groups based on the degree of similarity between their characteristics or behaviors. In this study, plant nutrition and fruit ripeness indicators were used to create management zones in a vineyard using Partition Around Medoids algorithm (PAM), an unsupervised Machine Learning clustering technique. The study was carried out in the municipality of Curitibanos, Santa Catarina, southern Brazil, in a vineyard plot composed of 4-year-old Sauvignon Blanc plants (n = 57). Zones defined using vine nutrition parameters showed strong spatial dependence, closely associated with relief, while those defined by fruit maturation parameters resulted in a more diverse mosaic, prompting further investigation due to the possible effects of

microclimate on plant physiology The results display the properties that defined each of the zones and indicate the feasibility of using the tool for management interventions.

KEYWORDS: ;

INTRODUÇÃO

A produção de vinhos finos requer a nutrição equilibrada das videiras, pois tanto a falta quanto o excesso de nutrientes podem comprometer a produtividade e a qualidade das uvas no curto e no longo prazo (ZHU; XIE; XU, 2022), com impactos sua aparência, cor, sabor, tamanho, aroma, capacidade de armazenamento pós-colheita e tolerância às pragas e doenças (BRUNETTO et al., 2015), o que posteriormente se reflete nas características dos mostos e vinhos resultantes (BRUNETTO et al., 2018; MPELASOKA et al., 2003; SKINNER et al., 2019).

Ademais, a produção de vinhos com características organolépticas superiores também demanda que as uvas sejam colhidas na sua maturidade ideal (NIIMI et al., 2017), visto que as uvas são frutos não climatéricos e, portanto, não continuam a maturar após serem colhidas. O estado fenológico das videiras é largamente governado pelo clima local (VAN LEEUWEN; DARRIET, 2016), topografia (MINNAAR; VAN DER RIJST; HUNTER, 2022), condições meteorológicas sazonais e práticas agronômicas (WEBB et al., 2012). Por sua vez, a determinação do momento mais apropriado de colheita apoia-se na avaliação da maturação dos frutos, geralmente realizada pela determinação do pH, Acidez Total Titulável e teores de Sólidos Solúveis Totais do mosto (KALOPESA et al., 2023), até que atinjam valores adequados para a alcançar o estilo de vinho desejado.

O objetivo da Viticultura de Precisão é definir um sistema de apoio à decisão para toda a gestão agrícola a fim de aumentar a eficiência no uso dos insumos agrícolas, resultando em redução de custos e aumento de retornos (AMMONIACI et al., 2021). O delineamento de zonas em um vinhedo é uma abordagem que permite adaptar o manejo às necessidades específicas bem como segregar a colheita em diferentes lotes que podem ser utilizados para produzir vinhos com características distintas (GONZÁLEZ-FERNÁNDEZ et al., 2019; URRETAVIZCAYA et al., 2014). Uma ferramenta útil para definição de zonas homogêneas de manejo é a Análise de Agrupamento, onde os objetos (no caso, as videiras) são agregados segundo critérios de proximidade definidos por uma função de distância, a qual busca minimizar as diferenças entre os membros de um mesmo grupo enquanto maximiza as diferenças entre grupos (XU; TIAN, 2015).

OBJETIVOS

Os objetivos deste estudo foram: investigar o uso de algoritmo de aprendizagem de máquina não supervisionado de agrupamento para a delimitação de zonas de manejo em um vinhedo comercial; e avaliar os efeitos da utilização de parâmetros relacionados à nutrição das videiras e à maturação dos frutos no zoneamento do talhão.

MATERIAL E MÉTODOS

Local de estudo

O estudo foi realizado em uma vinícola localizada no município de Curitibanos, Santa Catarina (27°12'18" S e 50°37'10" O), região Sul do Brasil, com altitude média aproximada de 1.000 m acima do nível do mar. O clima da região é classificado como Cfb (Köppen-Geiger), descrito como temperado, constantemente úmido e com verão ameno (ALVARES et al., 2013). As temperaturas médias anuais variam entre 15,8 °C e 17,9°C, com máximas entre 22,3°C e 25,8°C (máximas absolutas entre 30,1°C e 31°C) e mínimas entre 10,8°C e 12,9°C (mínimas absolutas entre 2°C e

3°C). A precipitação pluviométrica total anual vai de 1.460 mm a 1.820 mm (WREGE et al., 2012). No talhão investigado são cultivadas videiras para a produção de vinhos finos da cultivar Sauvignon Blanc, sobre porta-enxertos Paulsen 110, conduzidas em espaldeira e com 4 anos de idade. Destas, 57 vinhas foram identificadas e tiveram as suas coordenadas determinadas por GPS.

Análises

Amostras foliares das 57 videiras foram coletadas durante o florescimento, compreendendo 3 folhas completas (pecíolo + limbo) retiradas do terço médio das plantas. As amostras foram secas em estufa (65 ºC, 7 dias) e enviadas para análise laboratorial para obtenção dos teores médios de Nitrogênio (N), Fósforo (P), Potássio (K), Cálcio (Ca), Magnésio (Mg), Enxofre (S), Cobre (Cu), Zinco (Zn), Manganês (Mn) e Ferro (Fe), conforme metodologia descrita em TEDESCO et al. (1995).

A maturação dos frutos foi inferida por meio da caracterização físico-química de amostras contendo 30 bagas por pé, analisadas uma semana antes da colheita. Em laboratório foi feita a determinação dos teores de Sólidos Solúveis Totais - SST (ºBrix) com o auxílio de um refratômetro (Milwaukee, MA871), assim como pH do mosto e Acidez Total Titulável - ATT (mEq L-1) utilizando um Phmetro de bancada (Bel Engineering, PHS3BW) e soluções de Hidróxido de Sódio (NaOH 0,1 N) e indicador fenolftaleína (1%), conforme descrito em OIV (2023).

Processamento de dados

Os agrupamentos foram realizados utilizando o algoritmo Particionamento em Torno dos Medoides (PAM em Inglês). No PAM (KAUFMAN; ROUSSEEUW, 1990), um grupo de *n* objetos é dividido em número *k* de clusters (k-medoides) com base em suas semelhanças. Um medoide é um ponto no cluster a partir do qual a soma das distâncias até os outros pontos do cluster é mínima. Para evitar o impacto de *outliers* nos cálculos das distâncias foi utilizada o comprimento (ou distância) de Manhattan.

Para determinar os valores ótimos de *k* foram calculadas as somas de quadrados dentro do cluster para os diferentes valores de k = {1,2,...,8}. Com os resultados foram construídas curvas de retornos decrescentes para identificação dos pontos de inflexão, ou seja, os valores de *k* a partir dos quais a redução da soma total de quadrados não compensaria o custo adicional do incremento de *k*, também conhecido como método do Cotovelo (*Elbow method)*. Os valores determinados de *k* foram então utilizados para realizar o agrupamento das videiras considerando os dois diferentes conjuntos de parâmetros, relacionadas à nutrição das videiras (teores foliares de N, P, K, Ca, Mg, S, Cu, Zn, Mn e Fe) e à maturação dos frutos (SST, pH e ATT).

O processamento dos dados utilizou a linguagem R (R CORE TEAM, 2024) via RStudio (POSIT TEAM, 2024). A manipulação de dados e produção de gráficos foi feita utilizando a coleção de pacotes *tidyverse* (WICKHAM et al., 2019). Os agrupamentos empregaram o algoritmo PAM do pacote *cluster* (MAECHLER et al., 2023) implementado por meio do pacote *factoextra* (KASSAMBARA; MUNDT, 2020).

RESULTADOS E DISCUSSÃO

Número de zonas

O agrupamento considerando os parâmetros de nutrição apresentou uma inflexão evidente em sua curva quando *k* = 3 (Figura a). Para os parâmetros de maturação dos frutos, o ponto de inflexão se tornou menos óbvio, podendo ser atribuído aos valores *k* = 3 e *k* = 5 (Figura b). O valor de *k* obtido pelo método do Cotovelo é um resultado subjetivo, uma vez que trata-se de um método visual que não fornece uma métrica com a qual se possa indicar o ponto ótimo explicitamente (NAINGGOLAN

et al., 2019). Para reduzir a subjetividade é possível adaptar o método do cotovelo para que inclua um descriminante quantitativo, implicando em maior custo computacional (SHI et al., 2021), ou ainda recorrer a outros métodos como o da Silhueta (ROUSSEEUW, 1987), que mede quão semelhante um objeto é ao seu próprio cluster (coesão) em comparação com outros clusters (separação). Não obstante, a indicação dos métodos deve ser sempre ponderada pela avaliação da capacidade efetiva de se implementar e gerenciar um número crescente de zonas. Levando isto em consideração, ficou determinado que o agrupamento em 3 zonas seria o mais adequado para ambos conjuntos de variáveis..

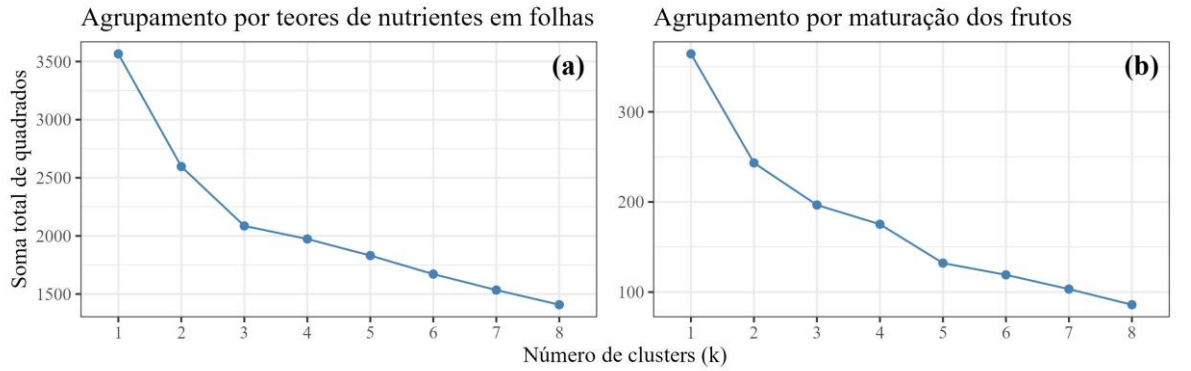


Figura 1: Soma dos quadrados para diferentes números de clusters (k) por agrupamento.

Zoneamento por nutrientes em folha

O agrupamento por parâmetros de nutrição das videiras produziu zonas bem delimitadas, seguindo padrões espaciais definidos pelo relevo. Existe no talhão uma declividade no sentido Noroeste (Δh ~ 12 m), predominando na região mais baixa as plantas pertencentes à zona N1 (n = 19), que se caracterizou pelo menor teor médio de K (10,5 g kg^{-1}) e os maiores teores médios de Mg (2,1 g kg^{-1}), Cu (15,0 mg kg^{-1}) e Mn (271,8 mg kg^{-1}). Já na porção mais alta predominaram videiras que constituem a zona N2 (n = 20), com os menores teores médios de N (23,3 g kg^{-1}) e S (2,6 g kg^{-1}) e os maiores teores médios de P (1,8 g kg^{-1}) e Ca (18,7 g kg^{-1}). A zona N3 (n = 18) ficou confinada na porção mais baixa da inclinação de sentido Nordeste (Δh ~ 2 m), onde foram registrados os menores teores médios de Cu (9,9 mg kg^{-1}), Zn (106,3 mg kg^{-1}) e Fe (63,9 mg kg^{-1}) (Figura). As zonas N1 e N3 ocupam as baixadas e compartilham teores semelhantes de N (27,4 e 29,8 g kg^{-1}), P (1,7 g kg^{-1} ambas), Ca (16,5 e 15,0 g kg^{-1}) e S (3,3 e 3,4 g kg^{-1}).

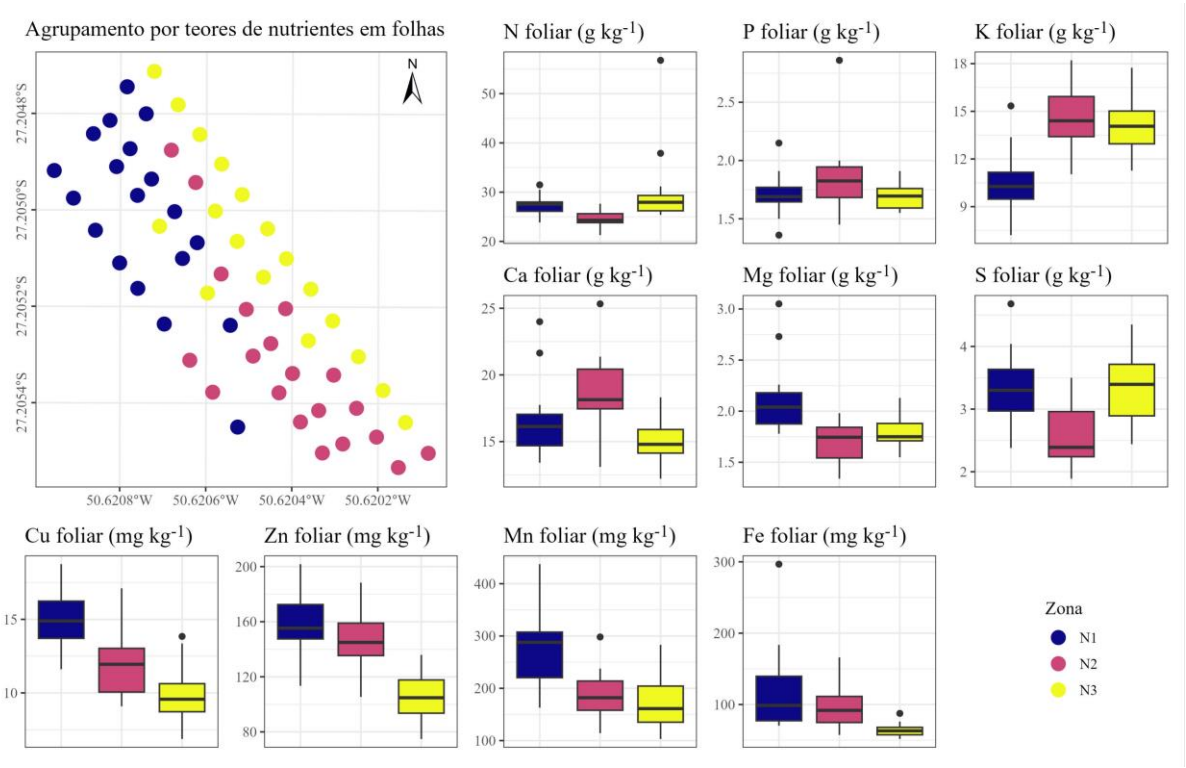


Figura 2: Distribuição espacial das videiras após agrupamento por teores de nutrientes em folhas e distribuição das variáveis por zona.

As características do relevo local suscitam distribuição heterogênea de propriedades que governam as reações químicas do solo, como textura e teores de matéria orgânica, afetando a disponibilidade de nutrientes para as raízes e com efeitos no desempenho e nos teores de matéria seca das videiras (GATTI et al., 2022). A nutrição de plantas perenes é um processo complexo e ainda sob investigação. Videiras são capazes de acumular e remobilizar nutrientes em suas reservas para atender às suas necessidades (HOLZAPFEL, 2019), o que deve ser considerado no manejo da fertilidade do solo. Não obstante, a crescente disponibilidade de dados induziu avanços na capacidade de processá-los, tornando possível produzir indicadores de fertilidade ajustados para condições geográficas específicas (ANDRADE et al., 2023), bem como distinguir diferentes perfis nutricionais entre cultivares (STEFANELLO et al., 2023), permitindo o aumento da eficiência e efetividade da adubação.

Zoneamento por maturação dos frutos

O agrupamento das videiras segundo parâmetros de maturação dos frutos não apresentou os mesmos padrões espaciais que o zoneamento considerando os teores de nutrientes nas folhas. A zona M1 (n = 18) foi caracterizada pelo menor teor médio de SST (21,7 °Bx) e valor médio de pH (3,12) relativamente baixo, concomitante ao mais alto valor médio de ATT (106,1 meq L^{-1}), predominando na fileira mais a oeste e nas bordas do talhão. A zona M2 (n = 13) abrigou o menor número de indivíduos, que estavam dispostos em manchas na região mais alta do terreno e na porção intermediária do talhão, junto ao caimento sentido Nordeste. A zona M2 foi caracterizada por um teor de SST (22.7 °Bx) mais alto que na zona M1, o mais alto valor médio de pH (3,24) e valor médio de ATT (91,6 meq L^{-1}) semelhante ao da zona M3 (Figura). Na região central predominou a zona M3 (n = 26), com as plantas que apresentaram teor médio de SST (22,7 °Bx) e ATT (91,1 meq L^{-1}) semelhantes à zona M2, porém com valores relativamente mais baixos de pH (3,13).

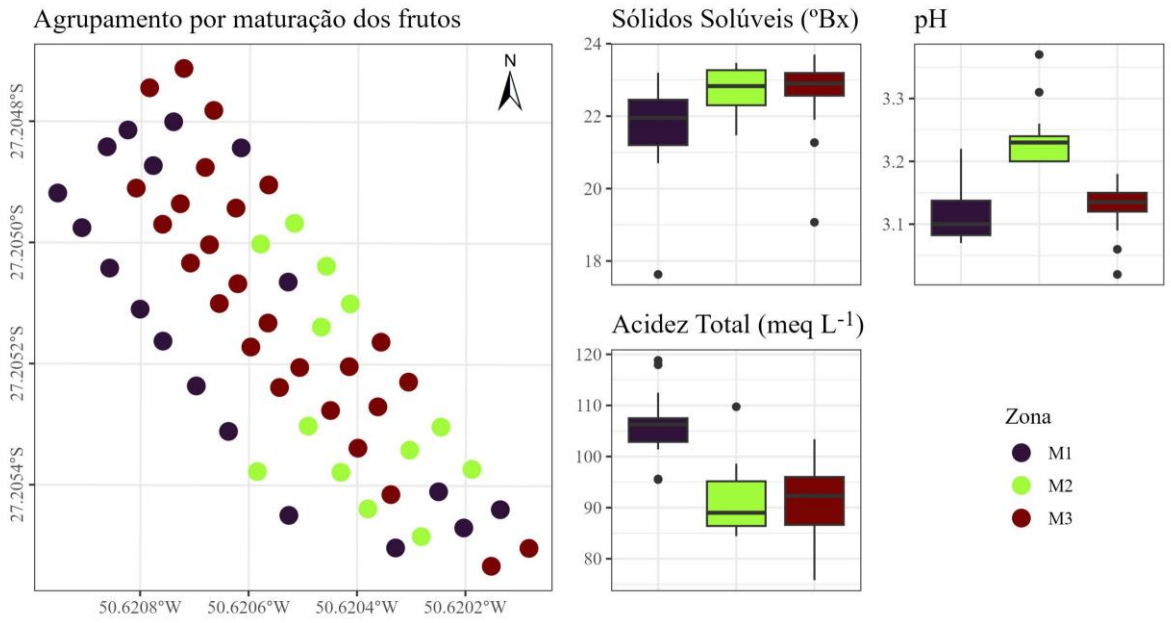


Figura 3: Distribuição espacial das videiras após agrupamento por parâmetros de maturação dos frutos e distribuição das variáveis por zona.

As condições meteorológicas desempenham um papel predominante na fisiologia da videira, influenciando o seu crescimento, desenvolvimento fenológico, rendimento e propriedades do mosto, afetando assim a qualidade do vinho (FRAGA et al., 2016). O relevo condiciona os fluxos hídricos na paisagem e pode induzir condições microclimáticas que interferem no comportamento das plantas. Zonas de baixada são mais susceptíveis à ocorrência de altos índices de umidade relativa do ar e elevam o risco de ocorrência de míldio (*Plasmopora viticola*) (SÔNEGO; GARRIDO; GRIGOLETTI JUNIOR, 2005). Também a velocidade e direção do vento influenciam na produção e qualidade dos frutos, seja pela capacidade de dispersar esporos de fungos, provocando infestações e comprometendo a saúde do vinhedo (MEZEI et al., 2022), seja pela redução da suscetibilidade das bagas às queimaduras solares (MÜLLER et al., 2023). Zonas mais altas podem receber maior incidência solar e atingir maiores temperaturas, interferindo na fotossíntese, transpiração e a composição das bagas (VENIOS et al., 2020), ao passo que o acúmulo de frio nas regiões mais baixas exerce efeitos sobre a dormência das gemas (ANZANELLO, 2019), contribuindo para a desuniformidade no desenvolvimento vegetal e na transição entre estados fenológicos. Ademais, a própria orientação das fileiras pode alterar composição fenólica das uvas (MINNAAR; VAN DER RIJST; HUNTER, 2022).

Evidente que a maturação dos frutos é um processo dinâmico e que, portanto, deve ser monitorado ao longo do tempo. Novos métodos incluem a utilização de sensores associados ao uso de inteligência artificial para inferir parâmetros de forma não-destrutiva (KALOPESA et al., 2023), o que pode agilizar e baratear este acompanhamento, gerando dados com uma grande resolução espacial e temporal que podem ser diretamente aplicados no zoneamento dos vinhedos.

CONCLUSÃO

A determinação de zonas de manejo utilizando Análise de Agrupamento mostrou-se um recurso bastante conveniente e poderoso para auxiliar a tomada de decisão. As principais características que separam os indivíduos nas diferentes zonas foram identificadas, podendo ser interpretadas por profissionais de modo a ajustar as práticas de manejo para obtenção de safras de maior rentabilidade e produtos de qualidade superior. O zoneamento utilizando parâmetros de nutrição das videiras apresentou forte caráter espacial, bastante associadas ao relevo, ao passo que o zoneamento por parâmetros de maturação dos frutos apresentou zonas em mosaico, suscitando maior investigação devido aos possíveis efeitos do microclima na fisiologia das plantas.

AGRADECIMENTOS

Agradecemos à Vinícola Berto Aguiar pela parceria e disponibilização do vinhedo para experimentação. Agradecemos também ao CNPq pelos recursos via processo nº 304642/2022-3, e a FAPESC pelo financiamento ao projeto i-Vitis, via projetos de TO Nº: 2021TR001707 e TO Nº: 2023TR000276.

REFERÊNCIAS

ALVARES, C. A. et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 1 dez. 2013.

AMMONIACI, M. et al. State of the Art of Monitoring Technologies and Data Processing for Precision Viticulture. **Agriculture**, v. 11, n. 3, p. 201, 28 fev. 2021.

ANDRADE, C. B. et al. Obtaining reference values for nutrients in vineyard soils through boundary line approach using Bayesian segmented quantile regression on commercial farm data. **European Journal of Agronomy**, v. 150, p. 126928, out. 2023.

ANZANELLO, R. Evolution of the grapevine bud dormancy under different thermal regimes. **Semina: Ciências Agrárias**, v. 40, n. 6Supl3, p. 3419, 16 out. 2019.

BRUNETTO, G. et al. The Role of Mineral Nutrition on Yields and Fruit Quality in Grapevine, Pear and Apple. **Revista Brasileira de Fruticultura**, v. 37, n. 4, p. 1089-1104, 2015.

BRUNETTO, G. et al. Produtividade de uvas e composição do mosto de videiras 'Cabernet Sauvignon' fertilizadas com composto orgânico e ureia. **Revista de Ciências Agroveterinárias**, v. 17, n. 2, p. 212-218, 19 jul. 2018.

FRAGA, H. et al. Modelling climate change impacts on viticultural yield, phenology and stress conditions in Europe. **Global Change Biology**, v. 22, n. 11, p. 3774-3788, 2016.

GATTI, M. et al. Effects of intra-vineyard variability and soil heterogeneity on vine performance, dry matter and nutrient partitioning. **Precision Agriculture**, v. 23, n. 1, p. 150-177, fev. 2022.

GONZÁLEZ-FERNÁNDEZ, A. B. et al. Delineating vineyard zones by fuzzy K-means algorithm based on grape sampling variables. **Scientia Horticulturae**, v. 243, p. 559-566, 2019.

HOLZAPFEL, B. P. Seasonal vine nutrient dynamics and distribution of Shiraz grapevines. **OENO One**, v. 53, n. 2, 29 maio 2019.

KALOPESA, E. et al. Rapid Determination of Wine Grape Maturity Level from pH, Titratable Acidity, and Sugar Content Using Non-Destructive In Situ Infrared Spectroscopy and Multi-Head Attention Convolutional Neural Networks. **Sensors**, v. 23, n. 23, p. 9536, 30 nov. 2023.

KASSAMBARA, A.; MUNDT, F. **factoextra: Extract and Visualize the Results of Multivariate Data Analyses**. , 2020. Disponível em: <https://CRAN.R-project.org/package=factoextra>

KAUFMAN, L.; ROUSSEEUW, P. J. **Finding Groups in Data: An Introduction to Cluster Analysis**. 1. ed. [s.l.] Wiley, 1990.

LEE, S.; LEE, D. K. What is the proper way to apply the multiple comparison test? **Korean Journal of Anesthesiology**, v. 71, n. 5, p. 353-360, 1 out. 2018.

MAECHLER, M. et al. **cluster: Cluster Analysis Basics and Extensions**. , 2023.

MEZEI, I. et al. Grapevine Downy Mildew Warning System Based on NB-IoT and Energy Harvesting Technology. **Electronics**, v. 11, n. 3, p. 356, 25 jan. 2022.

MINNAAR, D. P.; VAN DER RIJST, M.; HUNTER, K. Grapevine row orientation, vintage and grape ripeness effect on anthocyanins, flavan-3-ols, flavonols and phenolic acids: I. *Vitis vinifera* L. cv. Syrah grapes. **OENO One**, v. 56, n. 1, p. 275-293, 25 mar. 2022.

MPELASOKA, B. S. et al. A review of potassium nutrition in grapevines with special emphasis on berry accumulation. **Australian Journal of Grape and Wine Research**, v. 9, n. 3, p. 154-168, 1 out. 2003.

MÜLLER, K. et al. Wind speed, sun exposure and water status alter sunburn susceptibility of grape berries. **Frontiers in Plant Science**, v. 14, p. 1145274, 27 mar. 2023.

NAINGGOLAN, R. et al. Improved the Performance of the K-Means Cluster Using the Sum of Squared Error (SSE) optimized by using the Elbow Method. **Journal of Physics: Conference Series**, v. 1361, n. 1, p. 012015, 1 nov. 2019.

NIIMI, J. et al. Linking Sensory Properties and Chemical Composition of *Vitis vinifera* cv. Cabernet Sauvignon Grape Berries to Wine. **American Journal of Enology and Viticulture**, v. 68, n. 3, p. 357-368, jul. 2017.

OIV. **Compendium of international methods of wine and must analysis**. 12 Parvis l'UNESCO, 21000 Dijon: International Organisation of Vine and Wine, 2023. v. 1

POSIT TEAM. **RStudio: Integrated Development for R**. Boston, MA: Posit Software, PBC, 2024.

R CORE TEAM. **R: A Language and Environment for Statistical Computing**. Vienna, Austria: R Foundation for Statistical Computing, 2024.

ROUSSEEUW, P. J. Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. **Journal of Computational and Applied Mathematics**, v. 20, p. 53-65, nov. 1987.

SHI, C. et al. A quantitative discriminant method of elbow point for the optimal number of clusters in clustering algorithm. **EURASIP Journal on Wireless Communications and Networking**, v. 2021, n. 1, p. 31, dez. 2021.

SKINNER, P. W. et al. Sensory attributes of wines made from vines of differing phosphorus status. **Oeno One**, v. 53, n. 2, p. 205-219, 2019.

SÔNEGO, O. R.; GARRIDO, L. R.; GRIGOLETTI JUNIOR, A. **Principais doenças fúngicas da videira no Sul do Brasil**. Bento Gonçalves, RS: EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária, 2005. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/541425/principais-doencas-fungicas-da-videira-no-sul-do-brasil>.

STEFANELLO, L. et al. Phosphorus critical levels in soil and grapevine leaves for South Brazil vineyards: A Bayesian approach. **European Journal of Agronomy**, v. 144, p. 126752, mar. 2023.

TEDESCO, J. M. et al. **Análise de solo, plantas e outros materiais**. 2. ed. Porto Alegre, RS: Universidade Federal do Rio Grande do Sul, 1995.

URRETAVIZCAYA, I. et al. Oenological significance of vineyard management zones delineated using early grape sampling. **Precision Agriculture**, v. 15, n. 1, p. 111-129, fev. 2014.

VAN LEEUWEN, C.; DARRIET, P. The Impact of Climate Change on Viticulture and Wine Quality. **Journal of Wine Economics**, v. 11, n. 1, p. 150-167, maio 2016.

VENIOS, X. et al. Grapevine Responses to Heat Stress and Global Warming. **Plants**, v. 9, n. 12, p. 1754, 11 dez. 2020.

WEBB, L. B. et al. Earlier wine-grape ripening driven by climatic warming and drying and management practices. **Nature Climate Change**, v. 2, n. 4, p. 259-264, abr. 2012.

WICKHAM, H. et al. Welcome to the Tidyverse. **Journal of Open Source Software**, v. 4, n. 43, p. 1686, 21 nov. 2019.

WREGE, M. S. et al. **Atlas climático da Região Sul do Brasil: Estados do Paraná, Santa Catarina e Rio Grande do Sul**. 2. ed. Pelotas: Embrapa Clima Temperado, 2012.

XU, D.; TIAN, Y. A Comprehensive Survey of Clustering Algorithms. **Annals of Data Science**, v. 2, n. 2, p. 165-193, jun. 2015.

ZHU, Q.; XIE, X.; XU, Y. Fertilization Regulates Grape Yield and Quality in by Altering Soil Nutrients and the Microbial Community. **Sustainability**, v. 14, n. 17, p. 10857, 31 ago. 2022.

SOFTWARE PARA ESTIMATIVA DE PRODUTIVIDADE DA CANA-DE-AÇÚCAR BASEADO EM IMAGENS DE SENSORIAMENTO REMOTO

Caio Simplicio Arantes [1]; Eduardo Antonio Speranza [2]; Joao Francisco Goncalves Antunes [3]; Luiz Antonio Falaguasta Barbosa [2]; Geraldo Magela de Almeida Cançado [3]

[1]Bolsista. Campinas - SP. Embrapa Agricultura Digital; [2]Analista. Campinas - SP. Embrapa Agricultura Digital; [3]Pesquisador. Campinas - SP. Embrapa Agricultura Digital

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Na agricultura, a produtividade é um parâmetro crucial para determinar o sucesso de uma cultura. Por conseguinte, formas confiáveis de predizer o rendimento agrícola assumem um papel fundamental na tomada de decisões e no planejamento dos cultivos antes da colheita. Este trabalho descreve o desenvolvimento de um complemento no Sistema de Informação Geográfica QGIS capaz de gerar a estimativa de produtividade espacializada para a cultura da cana-de-açúcar a partir de uma imagem multiespectral, baseado em um modelo estatístico não-linear aplicado aos índices de vegetação. A estimativa obtida pode ser visualizada em um mapa ou acessada em planilha com resultado para cada um dos talhões de cana-de-açúcar avaliados.

PALAVRAS-CHAVE: Sistema de Informações Geográficas; Modelo Estatístico; Complemento

ABSTRACT

In agriculture, productivity is a crucial parameter for determining the success of a crop. Therefore, reliable ways to predict yield play a key role in decision-making and crop planning before harvesting. This work describes the development of a plugin in the Geographic Information System QGIS capable of generating spatialized yield predictions for sugarcane crops from multispectral images, based on a nonlinear statistical model applied to vegetation indices. The yield predictions obtained can be viewed on a map or accessed in a spreadsheet with results for each evaluated sugarcane plot.

KEYWORDS: ;

INTRODUÇÃO

A Embrapa Agricultura Digital e a Cooperativa de Plantadores de Cana do Estado de São Paulo (Coplacana) estabeleceram uma parceria voltada a cooperação técnico-científica com o objetivo de resgatar a produtividade da cultura da cana-de-açúcar no Brasil. Entre os objetivos estratégicos do projeto de inovação aberta, destaca-se a necessidade de modelar a produtividade de canaviais usando parâmetros de manejo em diferentes ambientes de produção (Embrapa Agricultura Digital, 2019).

A obtenção da estimativa de produtividade confiável de maneira antecipada à colheita é uma necessidade importante dos produtores de cana-de-açúcar por diversos motivos, tais como: planejamento mais eficiente da atividade agrícola e melhor gestão de recursos; auxílio à tomada de decisão sobre investimentos em irrigação, fertilização e controle de pragas e doenças; antecipação de receitas, cálculos de custo de produção e projeções de lucratividade; negociação de contratos mais precisas com usinas e empresas, evitando discrepâncias entre oferta e demanda (Pagani, et al. 2017). Nesse contexto, índices de vegetação obtidos a partir de dados de imagens de sensoriamento remoto, principalmente aquelas que podem ser obtidas gratuitamente pelo produtor, se tornam uma importante fonte de informações para a obtenção dessas estimativas a partir de ferramentas computacionais.

Como parte dos resultados desta cooperação, o modelo estatístico para estimativa de produtividade da cana-de-açúcar desenvolvido por Vansconcelos et al. (2013) subsidiou o desenvolvimento do complemento para o software QGIS (QGIS, 2024) desenvolvido neste trabalho. Trata-se de um modelo baseado em uma abordagem semiparamétrica associada a distribuição gaussiana inversa de índices vegetativos. Esses índices são métricas baseadas nas relações de refletância das bandas de uma imagem multiespectral e/ou RGB, que estão relacionados ao estádio vegetativo ou reprodutivo da cultura agrícola em um determinado momento (Jackson, 1991).

Complementos QGIS similares que envolvem atividades relacionadas a aplicação de conceitos de agricultura de precisão podem ser encontrados na literatura e no próprio repositório oficial da ferramenta. O complemento Smart-Map (Pereira et al., 2022) tem como objetivo auxiliar na integração e normalização de grade espacial de dados vetoriais referentes ao solo e à cultura, utilizando tecnologias de inteligência artificial e geoestatística para a geração de mapas contínuos. O complemento PAT - Precision Agriculture Tools (Ratcliff et al., 2018), mais completo, permite aos seus usuários, além de preparar dados vetoriais, gerar índices de vegetação a partir de imagens e zonas de manejo para aplicações de insumos a taxa variada em campo, dentre outras funcionalidades. Esses complementos estão mais focados na preparação dos dados, enquanto que o complemento proposto neste trabalho foi desenvolvido para uma atividade específica, que é a predição antecipada da produtividade em conjuntos de talhões de uma mesma região considerando um modelo estatístico.

OBJETIVOS

Este trabalho teve como objetivo desenvolver um complemento para o Sistema de Informação Geográfica QGIS para verificar a viabilidade desta plataforma na aplicação de um modelo de estimativa de produtividade já validado em áreas comerciais com imagens de sensoriamento remoto. Os requisitos definidos para este complemento foram: interface gráfica de usuário (GUI) própria para seleção de uma imagem multiespectral, suas respectivas bandas e seleção de uma camada vetorial, que são os contornos de áreas georreferenciadas dentro dos limites da imagem; geração de dados necessários para aplicar o modelo de estimativa de produtividade; acesso ao modelo por meio de uma Interface de Programação de Aplicações (API) via rede para obter a produtividade estimada por talhão; recursos para representação espacial em mapa dos resultados, e recurso para salvar os resultados em planilha.

MATERIAL E MÉTODOS

Esta seção descreve as etapas do desenvolvimento do complemento, mencionando as pilhas tecnológicas e as etapas envolvidas com relação a interação com a interface gráfica. Vale ressaltar que as etapas de desenvolvimento e validação do complemento foram realizadas utilizando bibliotecas computacionais gratuitas e de código aberto, e dados públicos fornecidos por satélites via sensoriamento remoto. Os contornos dos talhões avaliados foram fornecidos por produtores cooperados da Coplacana.

Plataforma: O QGIS foi escolhido como plataforma para a aplicação desenvolvida por ser gratuito, de código aberto (Licença Pública Geral GNU), e por ter recursos que permitem a automatização de operações de geoprocessamento via sua API Python, além de ser uma ferramenta consolidada no contexto da agricultura de precisão e em toda a comunidade de usuários de geotecnologias.

Interface gráfica de usuário: Para desenvolver a interface gráfica do usuário (GUI) do complemento foi utilizado o Qt Designer (Qt Group, 2024) O Qt Designer é uma ferramenta de arrastar e soltar, que permite trabalhar de maneira visual e é baseado no framework de interfaces gráficas Qt. Este último é acessível por meio do PyQt, um empacotador da linguagem Python para as bibliotecas Qt. PyQt fornece classes para criar caixas de diálogo, botões, caixas de texto, listas e outros *widgets*.

Também fornece funções para responder a eventos de interface do usuário, como cliques de botão ou alterações de texto.

Ao iniciar o QGIS, o arquivo resultante do Qt Designer (.ui) é convertido em código Python utilizando a ferramenta *pyuic*, que faz parte do PyQt. Este recurso cria uma classe que pode ser usada para criar a interface de usuário no complemento. Com a instância da classe criada, os *widgets* na interface de usuário podem ser acessados como atributos da instância. Isso permite que o complemento interaja com a interface de usuário, por exemplo, obtendo o texto de uma caixa de texto ou respondendo a um clique de botão.

Entrada de dados: Para obter a estimativa de produtividade é necessário adicionar na interface do QGIS uma camada de imagem multiespectral (camada raster) do estádio fenológico de maturação dos colmos, considerando o ciclo de desenvolvimento da cana-de-açúcar ao qual se deseja estimar a produtividade. Essa imagem deve sobrepor a toda a área dos talhões e conter as bandas R (Red), G (Green), B (Blue) e NIR (Near-Infrared). A numeração das bandas deve ser selecionada adequadamente pelo usuário assim como a camada vetorial (Figura 1). A data de captura da imagem em relação ao ciclo de maturação dos colmos da cana-de-açucar é importante para otimizar a estimativa, uma vez que reflete melhor as condições de treinamento do modelo, e deve ser a mais próxima possível do pico vegetativo.

É possível utilizar imagens públicas gratuitas de satélites, como as geradas pelos sensores Sentinel-2/MSI e Landsat-8/OLI, imagens comerciais de satélites (ex. PlanetScope), ou mesmo imagens geradas a partir de ARP (Aeronave Remotamente Pilotada).

Na escolha da camada vetorial, caso os polígonos já possuam um campo de identificação, o usuário pode selecioná-lo ou, caso contrário, um novo campo será criado com um prefixo selecionado.

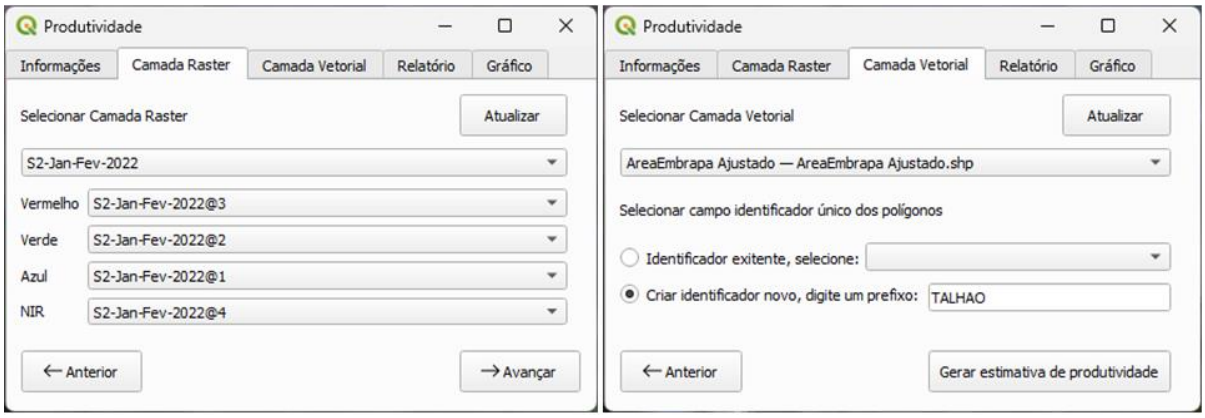


FIGURA 1. Interface de seleção da camada raster e camada vetorial.

Processamento de dados: A API Python do QGIS, o PyQGIS, é uma interface de programação que permite interagir com o QGIS usando a linguagem Python. Essa estratégia foi fundamental para o desenvolvimento deste complemento, pois fornece acesso às funcionalidades e aos dados do QGIS de maneira automatizada.

Após a entrada de dados e o acionamento pelo usuário da opção "Gerar estimativa de produtividade", classes e métodos do PyQGIS são acionados para realizar operações de geoprocessamento até o objetivo de produzir o mapa de estimativa de produtividade da seguinte forma: 1) Após obter os nomes das camadas raster e da camada vetorial selecionadas pelo usuário por meio das caixas de seleção, são obtidos os caminhos para as camadas selecionadas para poder manipulá-las; 2) Em seguida são criadas duas novas camadas ocultas no formato imagem, uma para o NDVI (Normalized Difference Vegetation Index) (Rouse et al., 1974) e uma para o VARI (Visible Atmospherically Resistant Index)(Gitelson et al., 2002), que são os índices vegetativos previstos para serem utilizados

pelo modelo estatístico de estimativa. Isso é feito usando a classe *QgsRasterCalculator* do PyQGIS, que permite realizar cálculos em bandas; 3) A média dos índices vegetativos por talhão é então calculada com o *QgsZonalStatistics*, classe do PyQGIS que permite calcular estatísticas para áreas definidas em uma camada de vetor (as zonas) com base em uma camada no formato imagem, atribuindo-os a novos campos de uma camada temporária utilizada para acessar atributos preditores e armazenar o resultado da estimativa de produtividade; e 4) A área de cada polígono, em hectare, também é avaliada por meio da classe *QgsExpression* do PyQGIS.

Com isso, obtém-se o conjunto de dados necessários para obter a estimativa de produtividade para cada polígono da camada vetorial, representando cada talhão produtivo. Para o cálculo correto dos dados é necessário que não ocorra sobreposição entre os polígonos e que cada um deles represente o contorno fidedigno de cada talhão da cultura.

Uso da API e acesso aos resultados: A abordagem utilizada para estimar a produtividade (Vasconcelos et al, 2023) baseou-se em um modelo estatístico semiparamétrico desenvolvido na linguagem de programação R (R Core Team, 2023), ajustado em uma função de predição encapsulada pelo pacote Plumber (Schloerke B, 2023). Por meio deste pacote, foi gerada uma API (Ofoeda et al., 2019). Para o desenvolvimento e teste deste complemento, a API foi hospedada em uma máquina virtual da estrutura de rede da Embrapa Agricultura Digital e disponibilizada a usuários da rede local por meio de um endereço de sub-rede.

Por meio de uma requisição HTTP GET, o conjunto de dados (Área, NDVI, VARI) de todos os talhões é enviado a API, que retorna com a estimativa de produtividade em formato JSON. Após a requisição, a camada vetorial original é duplicada, dando origem a uma nova camada vetorial temporária com novos campos adicionados a sua tabela de atributos: Área, NDVI, VARI, e a produtividade estimada, em tonelada/hectare (t/ha).

RESULTADOS E DISCUSSÃO

O resultado da estimativa de produtividade pode ser visualizado de múltiplas formas. Logo após o usuário clicar em *Gerar estimativa de produtividade* (Figura 1), uma aba do complemento é exibida com opções para visualizar os resultados (Figura 2). A estimativa de produtividade pode ser visualizada em tabela de atributos, em um mapa da extensão da propriedade (Figura 3) com uma paleta de cores que representa o resultado, conforme a legenda, em um *layout* de impressão do QGIS, o que permite ao usuário eventuais ajustes manuais no texto antes de imprimir ou exportar em formatos como PDF, e salvar em formato de planilha. A produtividade numérica do talhão é exibida, ou não, automaticamente conforme a disponibilidade de espaço na tela. Discussões sobre erros de estimativa em relação à produtividade real não foram o foco deste trabalho e já foram abordadas no artigo de referência do modelo utilizado (Vasconcelos et al, 2023).

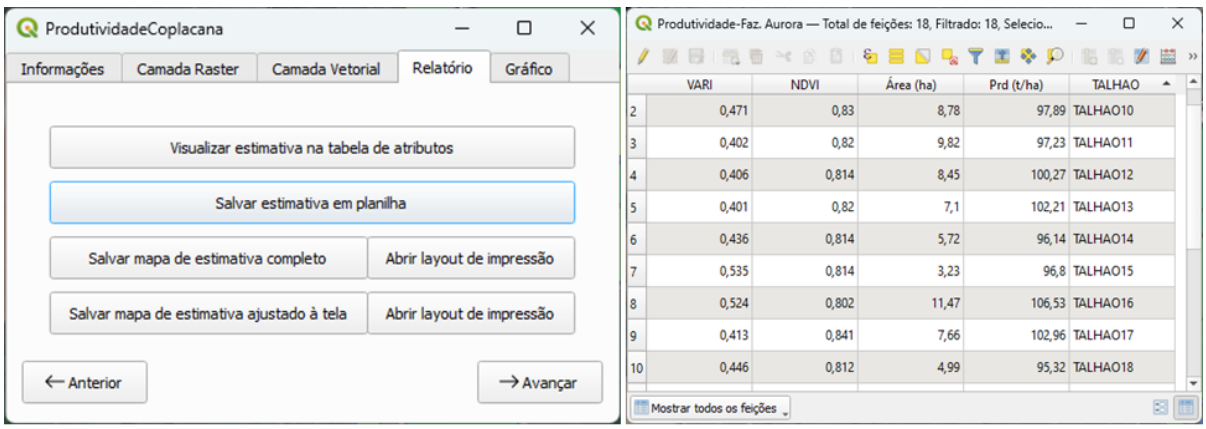


FIGURA 2. Relatório de resultados e tabela de atributos com novos campos calculados.

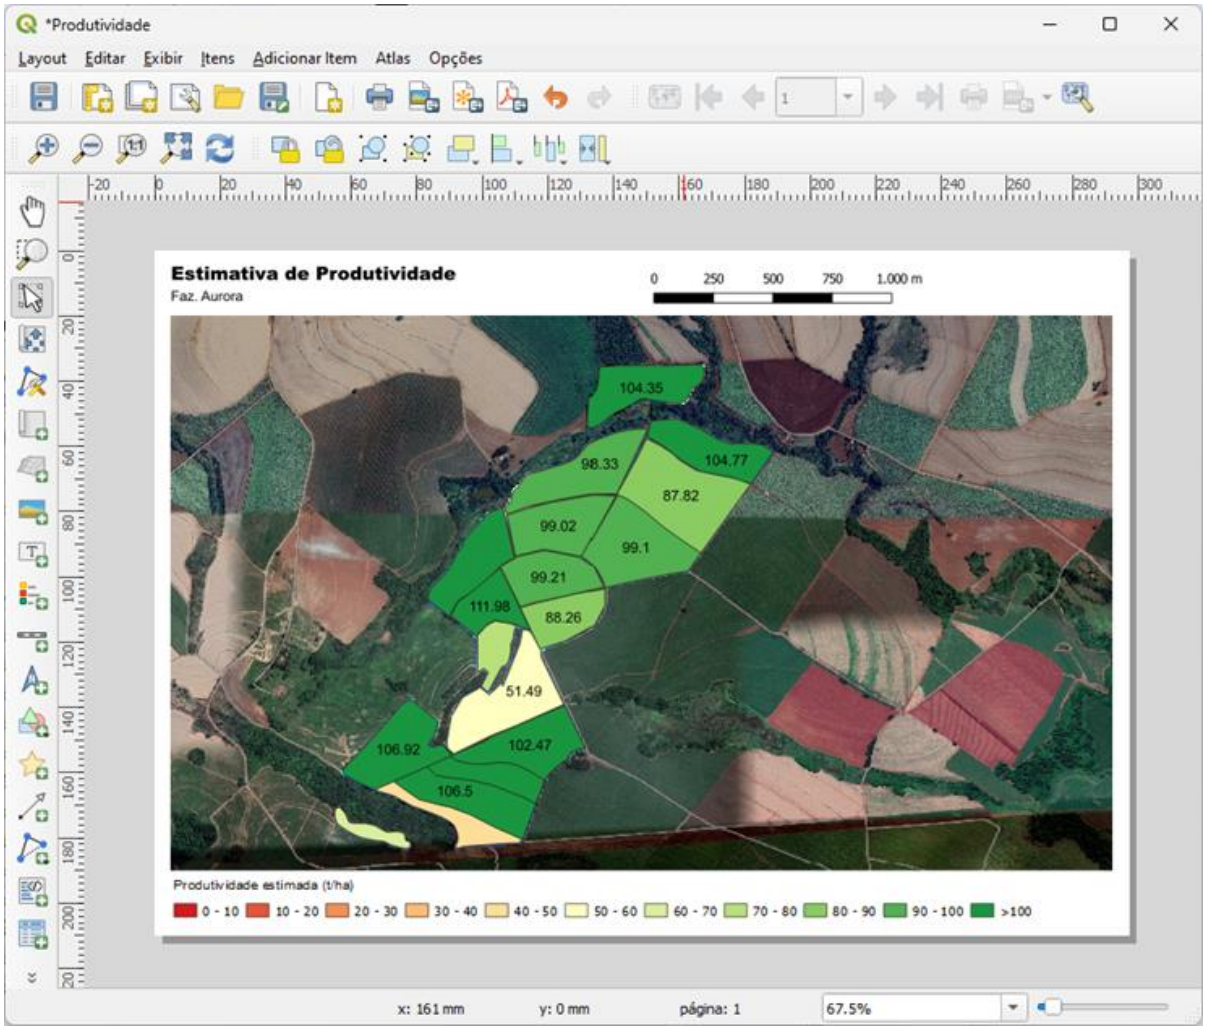


FIGURA 3. Layout de impressão gerado

CONCLUSÃO

O complemento desenvolvido no QGIS atingiu os requisitos definidos e demonstrou que a plataforma é uma alternativa viável de aplicação no contexto temático da agricultura digital. A aplicação de suas funcionalidades desenvolvidas a partir do modelo estatístico desenvolvido pela Embrapa Agricultura Digital em parceria com a Coplacana se mostrou eficiente para estimar a produtividade de áreas comerciais de cultivo da cana-de-açúcar com antecedência em relação à colheita.

A solução de acesso ao modelo via API se mostrou eficaz e apresenta o benefício de manter um certo nível de proteção à propriedade intelectual associada ao desenvolvimento do modelo e aos dados de treinamento. Em um próximo passo serão exploradas alternativas para tornar o uso do complemento de estimativa de produtividade mais amigável ao usuário final, com acesso via aplicativo para dispositivos móveis. Além disso, alternativas para uso no complemento do QGIS de imagens multiespectrais provenientes de satélites ou ARP deverão ser implementadas em futuras versões, facilitando a experiência do usuário.

Os resultados apresentados demonstraram que um usuário familiarizado com o uso do QGIS teria condições de utilizar o complemento desenvolvido para obter estimativas de produtividade em lavouras comerciais de cana-de açúcar, utilizando unicamente como fonte de informação imagens obtidas por satélites ou mesmo ARP. Portanto, a ferramenta apresentada neste trabalho possui funcionalidades capazes de auxiliar no planejamento, na gestão e na tomada de decisão de forma mais assertiva pelos canavicultores e usinas. Além disso, devido ao êxito da abordagem, estratégias

semelhantes deverão ser desenvolvidas para aplicação na estimativa de produtividade em outros cenários agrícolas, incluindo outras culturas tais como soja e milho.

AGRADECIMENTOS

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela bolsa de Especialista Visitante 3 concedida para o estudante do curso de Engenharia Agrícola da Universidade Estadual de Campinas (Unicamp) Caio S. Arantes. A Embrapa e a Coplacana pelo auxílio financeiro por meio do projeto SEG 30.19.90.005.00.00, intitulado "Desenvolvimento de soluções tecnológicas com escopo na recuperação da produtividade da cana-de-açúcar".

REFERÊNCIAS

EMBRAPA AGRICULTURA DIGITAL. **Desenvolvimento de soluções tecnológicas com escopo na recuperação da produtividade da cana-de-açúcar**. Projeto Embrapa - Coplacana, código SEG 30.19.90.005.00.00. 35p., 2019.

GITELSON, A. A. ET AL. Vegetation and soil lines in visible spectral space: A concept and technique for remote estimation of vegetation fraction. **International Journal of Remote Sensing**, v. 23, n. 13, p. 2537-2562, 2002.

VASCONCELOS ET AL. **Development and Validation of a Model Based on Vegetation Indices for the Prediction of Sugarcane Yield**, AgriEngineering 2023, 5(2), 698-719; https://doi.org/10.3390/agriengineering5020044, 2023.

SCHLOERKE B, ALLEN J. **Plumber: An API Generator for R.** https://www.rplumber.io, Disponível em: <https://github.com/rstudio/plumber/>. Acesso em: 03 de abril de 2024.

PAGANI, VALENTINA ET AL. Forecasting sugarcane yields using agro-climatic indicators and Canegro model: A case study in the main production region in Brazil. **Agricultural Systems**, v. 154, p. 45-52, 2017.

QT GROUP. **Qt Designer with QGIS 3.28.8 custom widgets.** Disponível em: <https://www.qt.io/>. Acesso em: 03 de abril de 2024.

QGIS.org. QGIS 3.28. **Geographic Information System API Documentation**. QGIS Association. Disponível em: https://qgis.org/pyqgis/3.28/index.html. Acesso em 26 mar. 2024.

JACKSON, R.D.; HUETE, A.R. **Interpreting vegetation indices**. Prev. Vet. Med, 11, 185-200, 1991.

OFOEDA, J.; BOATENG, R.; EFFAH, J. Application programming interface (API) research: A review of the past to inform the future. **International Journal of Enterprise Information Systems (IJEIS)**, v. 15, n. 3, p. 76-95, 2019.

PEREIRA, G. W. ET AL; **Smart-map: An open-source QGIS plugin for digital mapping using machine learning techniques and ordinary kriging**. Agronomy, *12*(6), 1350, 2022.

RATCLIFF, C., GOBBETT, D., & BRAMLEY, R. (2018). **PAT and QGIS-your new best mates for PA data analysis**. In: 21st Precision Agriculture Symposium, Sydney Institute of Agriculture. Procedings... Adelaide, v.1, p. 47-49, 2018.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. **Monitoring vegetation systems in the Great Plains with ERTS**. In: Fraden, S.C., Marcanti, E.P., Becker, M.A. (Eds.), Third ERTS Symposium. Proceedings... Washington D.C., NASA, v. 1, p. 309-317, 1974.

R CORE TEAM. **The R Project for Statistical Computing.** 2024. Disponível em: <http://www.r-project.org/>. Acesso em: 03 de abril de 2024.

ESTIMATIVA DA PRODUTIVIDADE NÃO OBTIDA DEVIDO ÀS FALHAS EM CANAVIAIS

Murilo Oliveira Cardoso [1]; Eudocio Rafael Otavio Da Silva [2]; Ricardo Canal Filho [3]; José Paulo Molin [4]
[1]Estudante de Eng° Agronômica, Lab. de Agricultura de Precisão, Depto. Engenharia de Biossistemas, Fone: (11) 940165634, oliveira.murilo@usp.br. Piracicaba - SP. Escola Superior De Agricultura Luiz de Queiroz, ESALQ USP Piracicaba - SP Universidade de Sao Paulo; [2]Eng° Agrícola e Ambiental, Doutorando, Lab. de Agricultura de Precisão, Depto. Engenharia de Biossistemas. Piracicaba - SP. Escola Superior De Agricultura Luiz de Queiroz, ESALQ USP Piracicaba - SP Universidade de Sao Paulo; [3]Engº Agrônomo, Doutorando, Lab. de Agricultura de Precisão, Depto. Engenharia de Biossistemas. Piracicaba - SP. Escola Superior De Agricultura Luiz de Queiroz, ESALQ USP Piracicaba - SP Universidade de Sao Paulo; [4]Engº Agrícola, Professor Titular, Lab. de Agricultura de Precisão, Depto. Engenharia de Biossistemas. Piracicaba - SP. Escola Superior De Agricultura Luiz de Queiroz, ESALQ USP Piracicaba - SP Universidade de Sao Paulo

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
A cana-de-açúcar apresenta custo de produção elevado, o que torna relevante obter informações relativas ao alcance das produtividades obtidas ao longo das safras para uma eficaz gestão da lavoura. Um dos desafios enfrentados na produção são as falhas (espaçamento entre plantas) nas fileiras, que afetam diretamente a produtividade do cultivo e são crescentes ao longo das safras. O objetivo do presente estudo foi utilizar um método estabelecido na literatura para obter mapas de produtividade em resolução de fileira de cana-de-açúcar e estimar a produtividade não obtida devido às falhas na fileira. Utilizando dados de colheita da cana em dois talhões comerciais, de falhas e de fileiras reconstituídas por veículo aéreo não tripulado em uma abordagem de mapeamento com polígonos de Voronoi, foram gerados mapas em resolução de fileira e estimada a produção de cana não obtidas devido às falhas. Como resultados, foram identificados 5,71 e 2,00 ha de falhas e estimados em 465,16 e 163,42 Mg a produção não obtida para os talhões 1 e 2, respectivamente. Foram identificados locais de alta e baixa produtividade em distâncias curtas na fileira e este mesmo padrão foi verificado para a falha na fileira. Tamanhos similares de comprimentos de falhas podem ocasionar perdas de produtividade diferentes devido os diferentes potenciais produtivos na região. Portanto, a abordagem possui potencial para o monitoramento e tomada de decisão no canavial.

PALAVRAS-CHAVE: Cana de Açucar; polígono de Voronoi; veículo aéreo não tripulado

ABSTRACT
Sugarcane has a high production cost, which makes it important to obtain information regarding yield obtained throughout the harvest for effective crop management. One of the challenges faced in the field are the row gaps (space between plants), which directly affect crop yield and presents a growing tendency throughout the seasons. The objective of the present study was to use a method established in the literature to obtain yield maps at sugarcane row resolution and estimate the yield not obtained due to these row gaps. Using data from sugarcane harvests of two commercial fields, rows and gaps reconstituted by Unmanned Aerial Vehicle in a mapping approach with Voronoi polygons, maps were generated at row resolution and the production not obtained due to row gaps were estimated. As a result, 5.71 and 2.00 ha of failures were identified and non-obtained production was estimated at 465.16 and 163.42 Mg for fields 1 and 2, respectively. Locations of high and low yield were identified at short distances in the row and this same pattern was verified for row gaps. Similar fault lengths can cause different yield losses due to the different yield potentials in the region. Therefore, the approach has potential for monitoring and aid the decision-making in the sugarcane production

KEYWORDS: sugarcane; Voronoi polygons; unmanned aerial vehicle

INTRODUÇÃO

Desde o século XVI, a cana-de-açúcar tem desempenhado um papel crucial na economia brasileira, liderando a produção mundial de açúcar, álcool e outros derivados (CONAB, 2022). O monitoramento dos canaviais tornou-se essencial para aplicar estratégias de otimização de recursos e tomar decisões específicas. Uma dessas abordagens é a resolução espacial em nível de fileira, com a predominante utilização de colhedoras embarcadas com Sistema Global de Navegação por Satélite (GNSS) de posicionamento acurado e veículos aéreos não tripulados (UAV) para reconstituir as fileiras da cana e medir os espaçamentos entre plantas, conhecidos como falhas (BARBOSA JÚNIOR et al., 2021). As falhas, caracterizadas como espaçamentos entre colmos onde não houve desenvolvimento de plantas (STOLF, 1986), representam um desafio para os gestores, pois indicam perda de produção na fileira. Monitorar esses dados juntamente com a investigação da variabilidade da produtividade em alta resolução espacial permite analisar como as falhas afetam a produtividade da cultura (MALDANER et al., 2024). Estudos recentes têm explorado o uso de dados de produtividade combinados com a reconstituição das fileiras de cana, para gerar mapas de produtividade em resolução de fileira (MALDANER & MOLIN, 2020). No entanto, são poucos os estudos que exploram a obtenção das falhas nessas situações e as relacionam com esses conjuntos de dados. A hipótese deste estudo é que é possível utilizar dados de produtividade e associá-los com dados de falhas na fileira, obtidos de UAV, para gerar informação sobre a não obtenção de biomassa de cana.

OBJETIVOS

O objetivo deste estudo foi utilizar um método estabelecido na literatura para obter mapas de produtividade em resolução de fileira de cana-de-açúcar e estimar a produtividade não obtida devido às falhas na fileira.

MATERIAL E MÉTODOS

Os dados foram obtidos de um campo comercial de cana-de-açúcar localizado no estado de São Paulo, Brasil. A região possui clima tropical de inverno seco, caracterizada como Aw, de acordo com a classificação climática de Köppen-Geiger. As áreas de estudo correspondem a dois talhões com 30,08 ha e 12,89 ha, cultivados com a variedade RB966928, de maturação precoce. O solo foi classificado como Latossolo Vermelho álico (SANTOS et al., 2018). A colheita foi realizada em 2021, terceiro corte da área, por colhedora de fileira única embarcada com GNSS. A produtividade foi obtida de um sistema sensor comercial (Solinftec, São Paulo, Brasil), que avalia a produtividade com base no peso total da cana colhida nas áreas de estudo, levando em consideração as variações de pressão de propulsão no sistema de picagem da colhedora. Uma descrição detalhada do sistema de mapeamento e validação da metodologia de obtenção da produtividade pode ser verificada em Maldaner et al. (2022). A aquisição dos dados de reconstituição de linhas e de falhas no canavial foi realizada por uma empresa prestadora de serviços utilizando um UAV, modelo eBee S.O.D.A, utilizando câmera RGB Sensefly S.O.D.A. O momento do voo foi baseado na altura média das plantas, cerca de 0,60 a 1,20 m de crescimento da cana, e na visibilidade da entrelinha, com resolução de pixel de 3,00 cm. Para identificar as falhas, foram obtidos os espaçamentos entre as plantas iguais ou maiores que 0,58 m, conforme extraído do ortomosaico gerado pelas imagens do UAV. As etapas de identificação e obtenção das falhas e da reconstituição das fileiras de cana pelo UAV são descritas com detalhes em Maldaner et al. (2024). O conjunto de dados de produtividade de cada talhão foram filtrados visando remover os dados discrepantes. Foi realizada análise exploratória e a estatística descritiva dos dados de produtividade e do comprimento de falhas, em que foram obtidos os valores médios, mínimos, máximos, mediana, coeficiente de variação (CV) e desvio padrão (DP). Utilizando a Equação 1 foram

quantificados a porcentagem de falhas (G%) em resolução de fileira de cana-de-açúcar no talhão (MOLIN & VEIGA, 2016).

$$G = \frac{di}{D} \quad \text{Eq. (48)}$$

em que: G% - porcentagem de falhas; d - comprimento da falha em determinado local *i*; D - comprimento da fileira de cana existente no talhão.

Para a elaboração dos mapas de produtividade em resolução de fileira utilizou-se como referência o trabalho de Maldaner e Molin (2020). Neste estudo, os autores utilizaram ferramentas de geoprocessamento e dados vetoriais em Sistema de Informação Geográfica (SIG), especificamente dados de produtividade, em geometria de pontos, para a construção de polígonos de Voronoi e os associaram à geometria de linhas, que representavam as fileiras da cana. O polígono de Voronoi subdivide o plano em *n* células (ou polígonos) envolvendo a parte do plano que está mais próxima de cada ponto, de tal forma que as bordas de polígonos adjacentes se encontram equidistantes de seus respectivos pontos geradores (ZENGIN & SEZER, 2021). Isso produz um mosaico que cobre todo o plano. Para cada talhão do presente estudo, foi gerado o polígono de Voronoi a partir dos dados de produtividade e realizada a intersecção desta camada com as que representam a reconstituição das fileiras e de falhas na fileira da cana. Para isto, utilizou-se a ferramenta "Intersecção" do QGIS. Seja P(x,y) a função de produtividade em um determinado ponto (x,y) do espaço, as fileiras reconstituídas do plantio de cana-de-açúcar podem ser representadas por uma função ?(x,y) que descreve a distribuição das fileiras. Os polígonos de Voronoi podem ser representados por uma função V(x,y), que atribui a cada ponto (x,y) do espaço o identificador do polígono de Voronoi correspondente. Cada polígono de Voronoi possui um valor de produtividade associado, denotado por Pv. Dessa forma, a intersecção entre as fileiras reconstituídas e os polígonos de Voronoi pode ser representada pela função de interseção I(x,y), definida como (Equação 1):

$$I(x,y) = \begin{cases} pv, se\ f(x,y) e\ V(x,y) se\ intersectam \\ 0, caso\ contrario \end{cases} \quad \text{Eq. (49)}$$

Assim, a função de interseção I(x,y) atribui um valor de produtividade Pv a cada ponto do espaço onde as fileiras reconstituídas e os polígonos de Voronoi se intersectam, e 0 aos demais pontos, gerando o mapa de produtividade em resolução de fileiras. Ainda, utilizando os mesmos termos da Equação 1, mas substituindo?(x,y) por uma função de distribuição das falhas nas fileiras de cana-de-açúcar ?falhas(x,y), obtém-se o mapa de comprimento de falhas com a estimativa do que deixou de ser produzido (Equação 2):

$$I = (x,y) \begin{cases} Pv,\ se\ ffalhas(x,y)\ e\ V(x,y)\ se\ intersectam \\ 0,\ caso\ contrario \end{cases} \quad \text{Eq. (50)}$$

Na Figura 1, estão ilustradas as etapas para geração dos mapas de produtividade a nível de fileiras de cana-de-açúcar, e da produção que deixou de ser obtida devido às falhas nas fileiras. Nota-se que, neste último, obtém-se a produtividade dos locais sem plantas (falhas) assumindo que, nessas falhas, a produtividade seria semelhante à dos seus vizinhos na fileira, que possuem plantas.

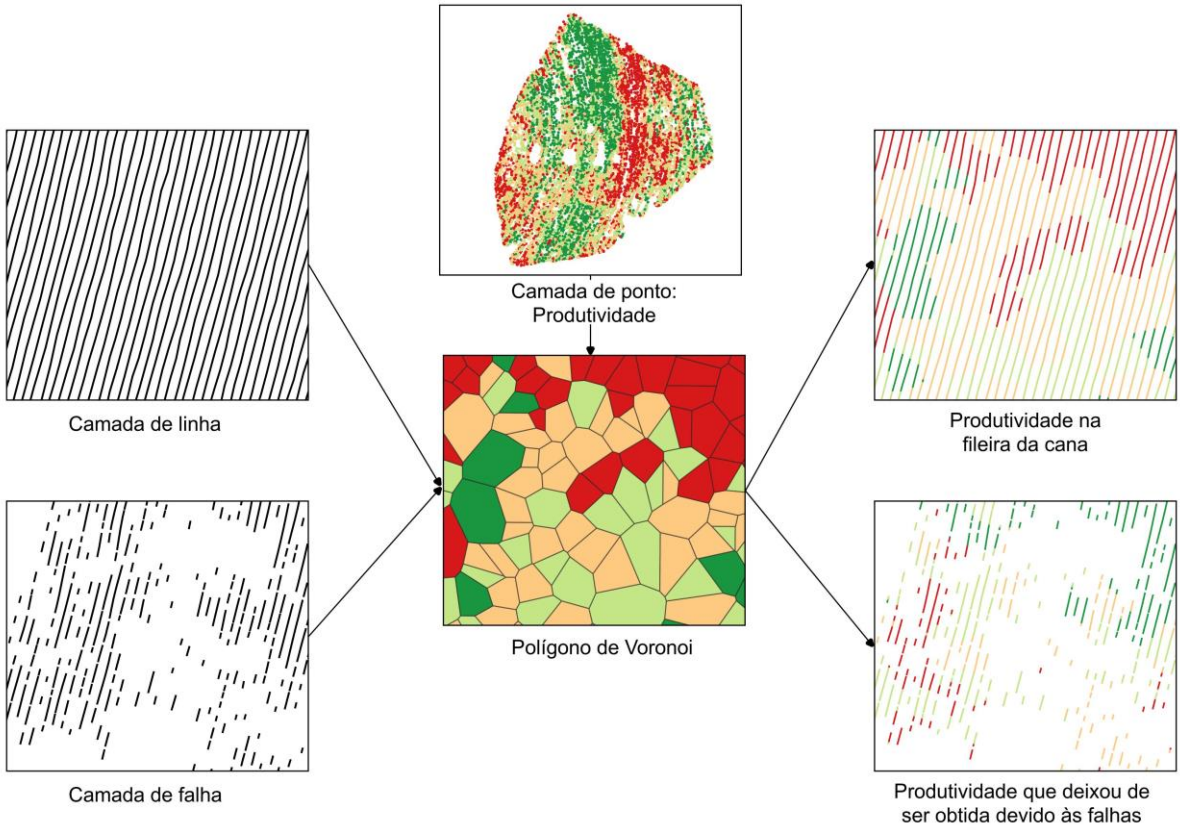


FIGURA 1. Etapas desenvolvidas utilizando ferramentas de geoprocessamento e as camadas de pontos de produtividade georreferenciados, falhas e reconstituição de fileiras da cana.

Destaca-se que, ao realizar a intersecção, ocorreram casos de falhas que estavam sob dois polígonos de Voronoi, recortando-as e sendo geradas duas falhas. Logo, o comprimento das falhas precisou ser calculado novamente para fazer a correção dos novos tamanhos de falhas. A estimativa da produção de cana não obtida devido às falhas foi obtida pela multiplicação das variáveis: produtividade que deixou de ser obtida devido às falhas, área do talhão, comprimento da falha e comprimento da fileira da cana.

RESULTADOS E DISCUSSÃO

Em ambos os talhões, os valores de CV e DP da produtividade indicam a amplitude de variação dos dados, o que demonstra variabilidade da produtividade no canavial (Tabela 1). Em determinadas regiões dos talhões, foram verificados valores de baixa e de alta produtividade em locais próximos, o que corrobora com Maldaner e Molin (2020) em que verificaram mudanças nos valores de produtividade em pequenas distâncias na fileira. Os valores médios de produtividade dos talhões 1 e 2, correspondentes a 83,00 e 85,60 Mg ha^{-1}, respectivamente, e foram superiores aos da média nacional para esta colheita, de 70,36 Mg ha^{-1} (CONAB, 2022), sendo talhões com adequado desempenho de produção para aquela safra.

TABELA 1. Estatística descritiva dos dados de produtividade e comprimento de falhas dos talhões 1 e 2.

Talhão	Variáveis	Méd	Medi	Máx	Mín	DP	CV	N falhas por comprimento (m)			
		Mg ha^{-1}					%	Total	≤1,50	1,50-5,00	≥5,00
1	Prod (Mg ha^{-1})	83,00	81,76	151,15	28,80	17,30	20,00	-	-	-	-
	Comp. Falhas (m)	1,50	1,00	27,00	0,58	1,40	49,00	34.632	22.009	10.627	1.996
2	Prod (Mg ha^{-1})	85,60	84,70	144,23	46,10	16,50	19,00	-	-	-	-
	Comp. falhas (m)	1,63	1,10	19,95	0,58	1,53	93,00	11.336	6.489	4.008	839

Méd: Média; Medi: Mediana; Máx: Máximo; Min: Mínimo; DP: Desvio Padrão; CV: Coeficiente de Variação; Prod: Produtividade; Comp. falhas: Comprimento de falhas; N falhas: Número de falhas; <1,50: ocorrência de comprimento de falha menor ou igual a ≤1,50 m; 1,50-5,00: ocorrência de comprimento de falha entre 1,50 e 5,00 m; > 5,00: ocorrência de comprimento de falha maior ou igual a ≥5,00 m.

Em relação aos comprimentos de falhas, foi verificado valores mínimos e máximos que variaram de 0,58 a 27,00 m para o talhão 1, enquanto no talhão 2 foi observada amplitude de dados de 0,58 a 19,95 m. As maiores ocorrências de comprimentos de falhas foram para os menores valores desta variável, onde 63% das falhas da área 1 e 57% da área 2 apresentaram comprimento menor ou igual a 1,50m, padrão que corresponde ao observado em Stolf (1986). Os valores de CV foram de 49,00 e 93,00%, nos talhões 1 e 2, respectivamente, o que indica heterogeneidade e alta variação do comprimento das falhas na fileira. A estimativa da produtividade que deixou de ser obtida devido às falhas apresentou valores similares aos dados de produtividade gerados no polígono de Voronoi. Isto faz sentido porque a camada da falha foi interseccionada com a do polígono. Ainda, esse resultado é coerente em vista de que se houvessem plantas nos locais falhados, provavelmente estas plantas deveriam apresentar valores similares aos seus vizinhos na fileira. Importante mencionar que essa estimativa não considera, para falhas maiores de que 0,58 m, possíveis compensações de biomassa de plantas próximas a locais em que não há plantas (STOLF, 1989). Foram identificados locais de alta e baixa produtividade em distâncias curtas. Isto pode ser visto pela distribuição de frequências e caracterização espacial da produtividade em resolução de fileiras na Figura 2A-B. As regiões em vermelho são as de menor produtividade, já as em verde as de maior produtividade, dentro do mesmo talhão. A caracterização da variabilidade espacial do que deixou de ser obtido de produtividade devido às falhas para os talhões 1 e 2 é apresentada na Figura 2C. As regiões em amarelo correspondem às de maiores estimativas de produtividade não obtida devido às falhas, enquanto as em violeta as de menores estimativas.

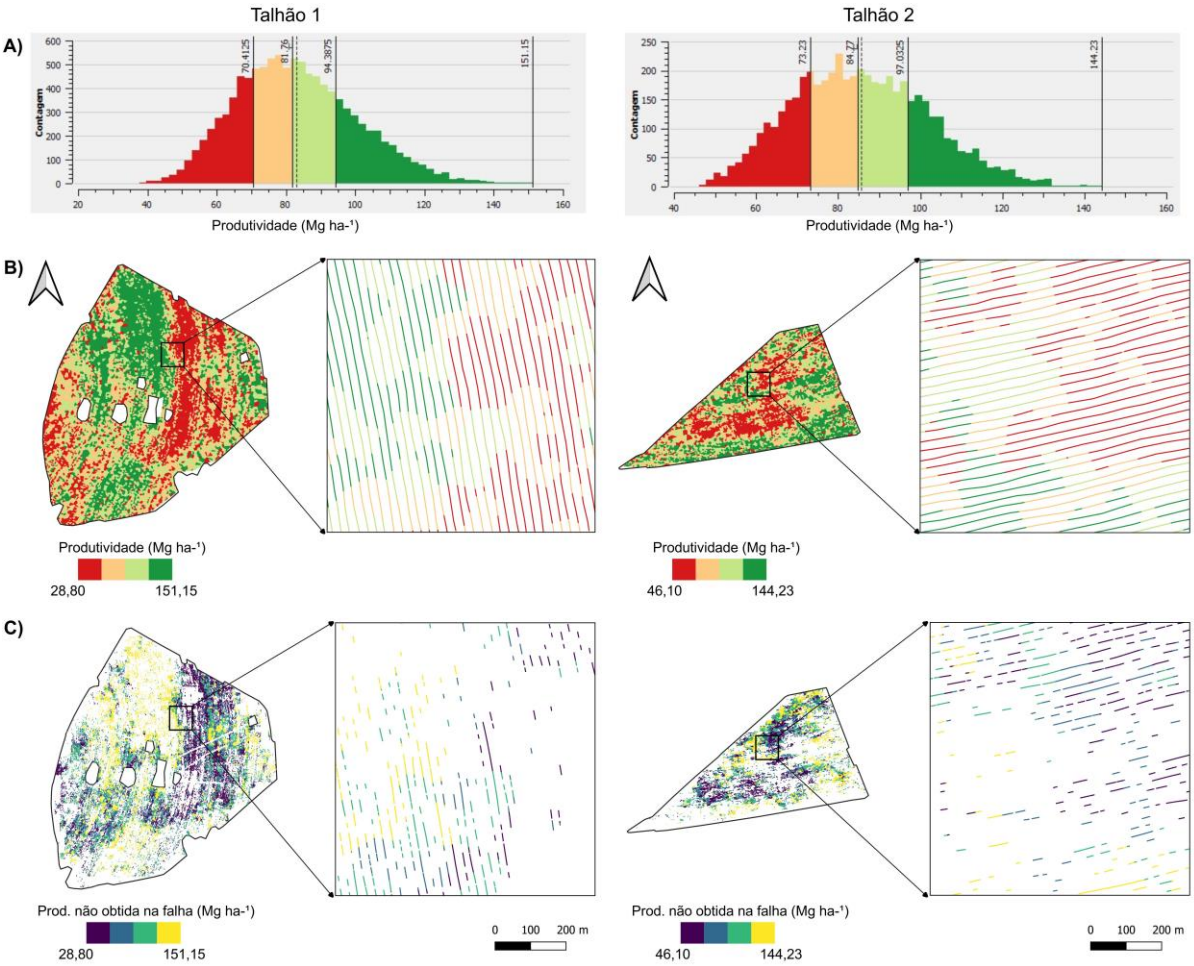


FIGURA 2. Distribuição de frequência da produtividade da cana (A), caracterização espacial da produtividade em resolução de fileira (B) e produtividade não obtida devido à falha na fileira (C) para os talhões 1 e 2.

Os talhões 1 e 2 apresentaram 19,28% e 15,05% de falhas, respectivamente. Isto representa que para o talhão 1, que possui 30,08 ha, cerca de 5,71 ha correspondem às falhas no canavial, ou seja, são 5,71 ha sem plantas e que deixaram de produzir biomassa de cana-de-açúcar. Para o talhão 1, a perda de produção foi estimada em 465,16 Mg. No talhão 2, de 12,89 ha, cerca de 2,00 ha correspondem à ocorrência de falhas na fileira da cana, com estimativa de perda de produção correspondente a 163,42 Mg. Isto é relevante porque o monitoramento indicando onde há ou não a presença de plantas apoiado a este tipo de mapa em resolução de fileiras, podem colaborar na tomada de decisão, permitindo a otimização de insumos, reduzindo custos e minimizando impactos ambientais (BARBOSA JÚNIOR et al., 2021). Observou-se também que, no mesmo talhão, tamanhos similares de comprimentos de falhas podem ocasionar produtividades não obtidas diferentes devido os diferentes potenciais produtivos na região. As falhas podem possuir o mesmo tamanho, porém dependendo da sua localização no canavial, podem indicar estimativas diferentes de não obtenção de biomassa. Ressalta-se que as interações existentes entre plantas dentro da fileira da cana, assim como a presença de falhas, são complexas e demandam mais investigações. Onde futuros trabalhos podem dizer o que proporcionou tamanha variação dentro de uma mesma área.

CONCLUSÃO

Utilizando um método estabelecido na literatura, foi possível gerar mapas em resolução de fileira da cana-de-açúcar e estimar a produtividade não obtida devido às falhas. Foram identificados locais de alta e baixa produtividade em distâncias curtas na fileira e este mesmo padrão foi verificado para a

falha na fileira. Tamanhos similares de comprimentos de falhas podem ocasionar perdas de produtividade diferentes devido os diferentes potenciais produtivos na região. Falhas de mesmo tamanho podem indicar estimativas diferentes de não obtenção de biomassa, a depender do potencial produtivo da região do talhão. Portanto, a abordagem possui potencial para o monitoramento e tomada de decisão no canavial.

AGRADECIMENTOS

À Solinftec pelo suporte na obtenção dos dados.

REFERÊNCIAS

BARBOSA JÚNIOR, M. R.; TEDESCO, D.; CORRÊA, R. G.; MOREIRA B. R. A.; SILVA, R, P.; ZERBATO, C. Mapping Gaps in Sugarcane by UAV RGB Imagery: The Lower and Earlier the Flight, the More Accurate. **Agronomy**, v. 11, n. 12, 2021.

CONAB. Boletim da safra de cana-de-açúcar. 2022. Disponível em: <https://www.conab.gov.br/info-agro/safras/cana/boletim-da-safra-de-cana-de-acucar >. Acesso em Jan 2024.

MALDANER, L. F.; MOLIN, J. P.; SILVA, E. R. O. Spatial-Temporal Analysis to Investigate the Influence of in-Row Plant Spacing on the Sugarcane Yield. **Sugar Tech**, v. 26, p. 194-206, 2024.

MALDANER, L. F.; CANATA, T. F.; MOLIN, J. P. An Approach to Sugarcane Yield Estimation Using Sensors in the Harvester and ZigBee Technology. **Sugar Tech**, v. 24, n. 3, p. 813-821, 2022.

MALDANER, L. F.; MOLIN, J. P. Data processing within rows for sugarcane yield mapping. **Scientia Agricola**, v. 77, n. 5, p. 1-8, 2020.

MOLIN, J. P.; VEIGA, J. P. S. Spatial variability of sugarcane row gaps: measurement and mapping. **Ciência e Agrotecnologia**, v. 40, n. 3, p. 347-355, 2016.

SANTOS, H. G. et al. **Sistema Brasileiro de Classificação de Solos**. 5. ed. Brasília, DF: Embrapa, 2018. 356p.

STOLF, R. Um modelo explicativo da competição entre colmos de um canavial e o vale da morte. **STAB**, v. 8, n. 2, p. 27-34, 1989.

STOLF, R. Methodology for gap evaluation on sugarcane lines. **STAB**, v. 4, n. 6, p.12-20, 1986.ZENGIN, R. S.; SEZER, V. A novel point inclusion test for convex polygons based on Voronoi tessellations. **Applied Mathematics And Computation**, v. 399, 126001, 2021

TÉCNICAS DE MACHINE LEARNING E SENSORIAMENTO REMOTO NA PREDIÇÃO DE ALTURA DE PLANTAS EM ÁREAS COMERCIAIS DE ALGODÃO

Maria Carolina da Silva Andrea [1]; Cristiano Ferreira de Oliveira [1]; Lucas Monteiro Bianchi [1]; Rafael Carlos dos Santos [1,2]; Caio Marchiorato de Gouveia [1,3]

[1]Cientista de Dados. Cuiabá, MT - Brasil. Nuvem Tecnologia; [2]Mestrando em Ciência da Computação. 12247-014, São José dos Campos, SP, Brasil. Universidade Federal de São Paulo (UNIFESP); [3]Mestrando em Engenharia Agrícola. 36570-900, Viçosa, MG, Brasil. Universidade Federal de Viçosa (UFV)

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

O algodão é uma importante cultura no agronegócio brasileiro. O adequado manejo da cultura demanda alto investimento tecnológico, no qual o uso eficiente de insumos de alto custo, como o regulador de crescimento, desempenha importante papel. Para desempenhar um manejo de insumos eficiente e alinhado com os preceitos de agricultura de precisão, ferramentas que permitam a caracterização do desenvolvimento da planta ao longo do ciclo tornam-se essenciais, como é o caso do sensoriamento remoto.

Considerando-se que a altura de plantas é uma importante variável para auxiliar no manejo do crescimento do algodão, o objetivo desse estudo foi estabelecer e avaliar um framework preditivo, com técnica supervisionada de *machine learning* para realizar a predição de altura de plantas em talhões comerciais de algodão. A construção do algoritmo foi baseada em dados de altura de plantas coletadas em talhões de três fazendas pertencentes ao mesmo grupo comercial durante as safras 2020/2021, 2021/2022 e 2022/2023, juntamente com dados de textura de solo e imagens de satélite de resolução espacial de 3 m. Dados de informação espectral (bandas e índices vegetativos), juntamente com informações fenológicas (dias após emergência), foram usados para treinamento e validação do algoritmo regressor e os hiperparâmetros do algoritmo foram ajustados por meio de processo de otimização bayesiana. O modelo apresentou boa performance preditiva para altura de plantas, com R^2 = 0.96, erro médio absoluto de 3,65 e erro máximo de 58,6 para o dataset de teste, sendo que dias após emergência e a banda Near-Infrared foram os melhores preditores. Os resultados indicaram que o framework é uma ferramenta útil na predição de altura de plantas, e representa uma possibilidade de auxílio no manejo do crescimento da cultura em condições comerciais.

PALAVRAS-CHAVE: machine learning; Gossypium hirsutum L.; crescimento vegetativo

ABSTRACT

Cotton is an important crop in Brazilian agribusiness. Proper crop management demands high technological investment, in which the efficient use of high-cost inputs, such as growth regulators, plays an important role. To perform efficient input management, aligned with the precepts of precision agriculture, tools that allow the characterization of plant development throughout the cycle become essential, as is the case with remote sensing. Considering that plant height is an important variable to assist in the management of cotton growth, the objective of this study was to establish and evaluate a predictive framework, with a supervised machine learning technique to predict plant height in commercial plots of cotton. The construction of the algorithm was based on plant height data collected in plots of three farms belonging to the same commercial group during the 2020/2021, 2021/2022 and 2022/2023 seasons, with soil texture data and satellite imagery with spatial resolution of 3 m. Spectral information data (bands and vegetative indices), and phenological information (days after emergence), were used for training and validation of the regressor algorithm and the algorithm's hyperparameters were adjusted through a Bayesian optimization process. The model showed good

predictive performance for plant height, with R^2 = 0.96, mean absolute error of 3.65 and maximum error of 58.6 for the test dataset, with days after emergence and the Near-Infrared band as the best predictors. The results indicated that the framework is a useful tool in predicting plant height, and represents a possibility of assistance in managing crop growth under large scale commercial conditions.

KEYWORDS: ;

INTRODUÇÃO

O Brasil e o estado do Mato Grosso são grandes produtores da cultura do algodão. Na safra 2022-2023, o estado teve uma área cultivada de 1.190 mil hectares (95% da área cultivada da região Centro-Oeste e 71% do território nacional) e uma produtividade bruta média de 4.580 kg/ha (CONAB, 2023). A cultura apresenta elevado risco devido ao seu alto custo de produção e aos riscos climáticos aos quais está sujeita no Cerrado brasileiro, região em que se concentra a produção. Um dos insumos que contribui para esse elevado risco é o regulador de crescimento, insumo necessário ao equilíbrio do desenvolvimento vegetativo e produtivo e à cultura atingir porte adequado ao final do seu ciclo. Tal como acontece com muitos insumos no ciclo de produção, recomenda-se que o regulador de crescimento seja aplicado de acordo com as necessidades específicas da área no contexto da gestão na agricultura de precisão (PLANT, 2001). Atualmente, a disponibilidade de tecnologias de sensoriamento remoto e técnicas de análise de dados tem auxiliado os estudos sobre as relações entre as características fenotípicas de plantas e a radiação eletromagnética, permitindo aplicações mais eficientes da agricultura de precisão. A combinação entre o sensoriamento remoto, que permite o monitoramento de grandes áreas, e técnicas como *machine learning*, que apresentam eficiência e robustez em análises preditivas, por exemplo, é um importante tipo de ferramenta nesses estudos (van DIJK et al., 2021). Estudos nesta área têm como fundamento determinar a conexão entre a vegetação e a radiação eletromagnética obtida a partir dos produtos de sensoriamento remoto (bandas espectrais, índices vegetativos) (XUE e SU, 2017). As relações indiretas estabelecidas com as características da vegetação, como altura de plantas, biomassa e outras, é frequentemente objeto de estudos empíricos (GUTIERREZ et al., 2012). Estudos recentes apresentaram a utilidade dos dados de sensoriamento remoto, especialmente os índices vegetativos, no manejo do algodão por meio do planejamento da aplicação do regulador de crescimento sob taxas variáveis (SOUZA et al., 2017). Embora reconhecendo a complexidade dos conceitos nas relações entre radiação eletromagnética e características da cultura, este estudo foi conduzido com o objetivo principal de desenvolver e avaliar um framework para realizar a predição de altura de plantas como suporte ao manejo do desenvolvimento da cultura do algodão em condições de cultivo comercial em larga escala.

OBJETIVOS

O objetivo desse estudo foi desenvolver e avaliar um framework baseado em dados de sensoriamento remoto e técnicas de machine learning para realizar a predição de altura de plantas como suporte ao manejo do desenvolvimento da cultura do algodão em condições de cultivo comercial em larga escala.

MATERIAL E MÉTODOS

As análises do presente estudo foram divididas em três etapas: (i) a construção do dataset e manipulação dos dados para a etapa preditiva; (ii) o ajuste do modelo preditivo e avaliação de sua performance, e (iii) predição de altura de plantas em dois talhões comerciais.

Construção do dataset e manipulação dos dados: O dataset usado para a modelagem preditiva foi baseado em dados de diversos talhões, coletados durante as safras 2020/2021, 2021/2022 e 2022/2023 de três fazendas de produção de algodão pertencentes ao mesmo grupo comercial, localizadas no

estado de Mato Grosso. Essas fazendas possuem cultivo de algodão predominantemente em sistemas de safrinha e sequeiro, e seguem conjunto de medidas de manejo padronizadas e de alto nível tecnológico (manejo de nutrição e adubação, manejo fitossanitário e de demais insumos), respeitando as suas especificidades locais (variabilidade nas condições de solo e climáticas). Todas as fazendas localizam-se em região na qual o clima é classificado como Tropical úmido Aw, caracterizado por verão chuvoso e inverno seco, de acordo com metodologia de Köppen. Algumas de suas características gerais podem ser observadas na Tabela 1.

Tabela 1. Características gerais dos dados usados na etapa de modelagem preditiva de altura de plantas.

Fazenda	Número talhões	Número de observações	Intervalo textural dos talhões
1	65	1262	arenoso (15%) - médio-argiloso (25-40%)
2	35	1228	arenoso (15%) - argiloso (40 - 60%)
3	108	20756	arenoso (15%) - argiloso (40 - 60%)

[1]Número total de talhões nos quais foram coletados dados de monitoramento de plantas ao longo das safras 2020-2021, 2021-2022 e 2022-2023; [2]Número total de pontos de monitoramento de plantas geograficamente localizados dos talhões ao longo das safras 2020-2021, 2021-2022 e 2022-2023; [3]Intervalo textural que refere-se à amplitude da classificação média dos talhões nas fazendas.

Os dados de entrada da modelagem preditiva são representados pelas leituras de altura de plantas feitas no monitoramento em campo em condições comerciais, dias após emergência (dae), e informações espectrais obtidas de imagens de satélite. Cada observação é um ponto monitorado dentro de um talhão. Os dados de monitoramento representam as atividades usuais durante as safras comerciais nessas fazendas, seguindo a mesma metodologia, abrangendo grande variedade de talhões, e variam quanto à sua disponibilidade espacial e temporal (há talhões com maior freqüência de leituras do que outros). O uso dessas informações compiladas durante quase três safras e totalizando elevado número de observações (pouco mais de 20 mil pontos geograficamente localizados com medição de altura de plantas) foi fundamental ao desenvolvimento de algoritmo de *machine learning* com finalidade preditiva, que requer grande quantidade de exemplos para melhores performances dos modelos. Foram selecionados dois talhões dessas fazendas que apresentaram maior frequência e melhor distribuição dos pontos amostrais, permitindo uma análise mais detalhada dos resultados. Esses talhões diferem entre si quanto à variabilidade textural do solo, que impacta todo o desenvolvimento da planta durante o ciclo. Algumas das principais características dos talhões, bem como a distribuição das amostras de altura de plantas coletadas em campo na safra de 2022-2023 podem ser observadas na Tabela 2 e Figuras 1 e 2, respectivamente.

Tabela 2. Características gerais do talhão avaliado durante a safra 22/23.

Talhão (Fazenda)	[1]Textura de solo	Data de emergência	Estande de plantas	Chuva acumulada (mm)	Data de colheita	Produtividade (@/ha)
A (1)	Médio-argiloso	14/01/2023	9,4	1199	21/07/2023	365
B (3)	Médio-argiloso	10/02/2023	10,9	982	29/08/2023	242

[1]Textura de solo se refere à uma condição média de todo o talhão; [2]Chuva acumulada entre emergência e colheita.

As amostras de altura de plantas coletadas em campo foram realizadas em esquema de grade distribuída por toda a área do talhão (Figura 1), com frequência média de uma leitura a cada dez dias durante o período entre as fases fenológicas do algodão de V5 a F4, aproximadamente. Os pontos de altura coletados representam uma média de 3 - 5 plantas em cada ponto geograficamente localizado, e medidos *in loco* com trena. Esses dados foram obtidos durante as safras 2020-2021, 2021-2022, e parte da safra 2022-2023 (até 15/03/23), e em cada observação consta também a informação dos dias após emergência.

Com relação às informações espectrais, os dados tiveram como origem as imagens de satélite obtidas da constelação Planetscope (PLANET, 2022), com as características principais de 3 m de resolução espacial, resolução temporal diária, e resolução espectral que abrange as bandas da faixa do espectro visível e região do infra-vermelho próximo. Com esses produtos espectrais, as seguintes variáveis foram utilizadas na etapa de modelagem preditiva (Tabela 3):

TABELA 3. Descrição dos produtos espectrais usados na modelagem preditiva de altura de plantas.

Banda / IV	Descrição	Equação	Referência
B, G, R, NIR	Blue, Green, Red, Near-Infrared	-	-
NDVI	Normalized Difference Vegetation Index	(NIR ? R) / (NIR + R)	TUCKER, 1979
DVI	Difference Vegetation Index	NIR ? R	TUCKER, 1979
GNDVI	Green Normalized Difference Vegetation Index	(NIR ? G) / (NIR + G)	GITELSON et al., 1996
MSAVI2	Modified Secondary Soil-Adjusted Vegetation Index	2 ? NIR + 1 ? ?(2 ? NIR + 1) ? 8 ? (NIR ? R) / 2	MRÓZ e SOBIERAJ, 2004

O conjunto de dados foi ajustado de maneira que cada observação fosse organizada com relação à espacialidade (pareamento de informação espectral mais próxima a cada ponto de leitura de altura) e à temporalidade (uso de imagem de satélite sem nebulosidade em intervalo de até 5 dias mais próximos à data de leitura em campo). O processo resultou no dataset para a fase de modelagem preditiva, sendo que as variáveis independentes foram representadas pelas informações espectrais e fenologia (dias após emergência do respectivo ponto amostrado), e a variável dependente sendo a altura de plantas.

Modelagem preditiva de altura de plantas: A modelagem preditiva foi feita por meio de algoritmo de regressão, o modelo *Random Forest*. Esse algoritmo de *machine learning*, que vem sendo amplamente usado em estudos na agricultura, e é um método considerado robusto e com boa performance geral. Entre suas principais características estão a de que esse é um método *ensemble* e baseado em árvores - constrói diversas árvores e combina suas predições para o resultado final - e tem como algumas de suas principais vantagens a robustez ao superajuste, além de lidar com relações mais complexas e não lineares de maneira eficiente. Porém deve-se atentar à sua interpretabilidade e ao ajuste dos seus hiperparâmetros (LOUPPE, 2014).

Os dados foram divididos em treino, validação e teste (70%, 15% e 15%, respectivamente). Foi realizado ajuste dos hiperparâmetros por meio de processo de otimização bayesiana, devido à sua maior eficiência em relação a outros processos, como o de busca exaustiva (WU et al., 2019). A otimização bayesiana, em resumo, é um processo no qual é usado um modelo probabilístico que aproxima a performance da função-objetiva (como o erro médio quadrático), de maneira a equilibrar a exploração e o aproveitamento, dando mais ênfase às regiões mais promissoras, e sendo mais

eficiente em termos computacionais do que algoritmos de busca exaustiva, como o *grid-search*. Mais detalhes sobre seu funcionamento podem ser encontrados em Wu et al, 2019.

A performance do modelo após processo de otimização foi avaliada, e as predições de altura de plantas foram avaliadas utilizando-se as métricas de R^2 (R-squared), Erro médio absoluto (*Mean Absolute Error* - MAE) e Erro quadrático médio (*Mean Squared Error* - MSE) e Erro máximo. A escolha pelo uso dos produtos espectrais e modelo regressor específicos baseia-se em estudo previamente realizado, que avaliou a performance de diversas variáveis espectrais e modelos regressores para predição de altura de plantas (Andrea et al. 2023). O processo de modelagem e análise dos dados foi realizado utilizando a linguagem *python* de programação e pacotes específicos para cada etapa, e os mapas foram desenvolvidos utilizando-se o QGIS (QGIS, 2024). Após a construção e ajuste do modelo preditivo, datasets dos dois talhões usados para a presente avaliação foram formados, na mesma grade de distribuição de pontos correspondente aos dados de textura de solos (10 m x 10 m) e data posterior ao final do dataset de modelagem, contendo as informações espectrais e de dias após emergência. A esse dataset de dados não compreendidos pelo modelo, o algoritmo foi aplicado, resultando em dados de altura de plantas preditos pelo modelo de *machine learning*.

RESULTADOS E DISCUSSÃO

Dataset de modelagem e Algoritmo preditivo: Após o desenvolvimento do dataset para modelagem, foi realizada uma análise exploratória dos dados, para que a relação entre as variáveis dependente e independentes pudesse ser melhor detalhada. A correlação (*Spearman*) entre as variáveis usadas na modelagem preditiva pode ser observada na Figura 2.

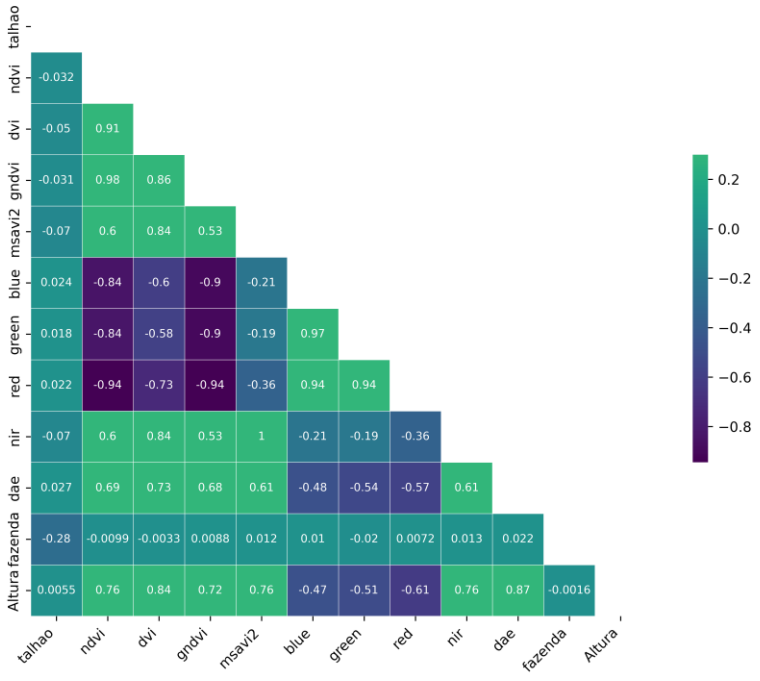


FIGURA 2. Correlação entre as variáveis usadas na modelagem preditiva de altura de plantas em talhões comerciais de algodão. Dados referente às safras 2020-2021, 2021-2022 e 2022-2023, durante todo o ciclo de desenvolvimento da planta.

É possível observar que a variável dependente (altura de plantas) apresenta correlações fortes (acima de 0,5) e positivas com as variáveis GNDVI, NDVI, MSAVI2, NIR, DVI e dae, sendo a mais alta com essa última variável. Já as demais variáveis, bandas B, G e R, apresentaram correlações negativas e um pouco mais fracas que as demais. Tais resultados estão de acordo com estudos que já avaliaram esse tipo de relação: a forte relação linear de altura de plantas com sua idade e relações positivas com índices vegetativos e negativas com as bandas do espectro visível (PAYERO et al., 2004). Destaca-se que essa correlação considera todo o ciclo de desenvolvimento da safra, desde as primeiras até as últimas leituras de monitoramento em campo de altura de plantas, portanto abrangendo diversas fases fenológicas. Em fases fenológicas específicas, as relações entre as variáveis podem sofrer alterações (ANDREA et al., 2023). Após o processo de ajuste dos hiperparâmetros por meio do processo de otimização, o desempenho do conjunto de teste do algoritmo foi avaliado, como pode ser observado na Tabela 4 e Figura 3.

TABELA 4. Métricas da performance do modelo regressor *Random Forest* para predição de altura de plantas no dataset de teste, após processo de ajuste dos hiperparâmetros por meio de otimização *bayesiana*.

[1]MSE	[2]Erro máximo	[2]MAE	[4]R^2
43	58,3	3,65	0,96

[1]Mean Squared Error (erro quadrático médio); [2]Erro máximo ; [3]Mean Absolute Error (erro médio absoluto); [4](coeficiente de determinação).

Os resultados de performance preditiva indicam boa performance do algoritmo, evidenciado pelos valores das métricas MSE, MAE e R^2. Trabalhos como o de TEODORO et al., 2021 (soja) e JAMALI et al., (2023) (trigo) também usaram imagens orbitais na predição de altura de plantas, encontrando R^2 entre 0,60 e 0,80. O valor de erro máximo desse estudo, por sua vez, é um indicativo sobre a variabilidade dos dados, e consequência da quantidade e variedade de talhões usados na modelagem. Poucos estudos têm como objetivo único a avaliação de predição de alturas de planta na cultura do algodão, visto que em geral tal processo encontra-se associado à estimativas de biomassa e produtividade (HERR et al. 2023). Na Figura 3 pode-se observar a relação entre observado e predito, por meio de gráfico de dispersão e histograma. Fica clara a variabilidade e amplitude dos dados, visto que referem-se ao ciclo todo de grande quantidade de talhões e quase três safras completas. Tal fato, apesar de ser considerado positivo para o desenvolvimento de algoritmo de *machine learning*, também pode ser considerado um desafio ao tratar de vasta quantidade de condições de desenvolvimento das plantas.

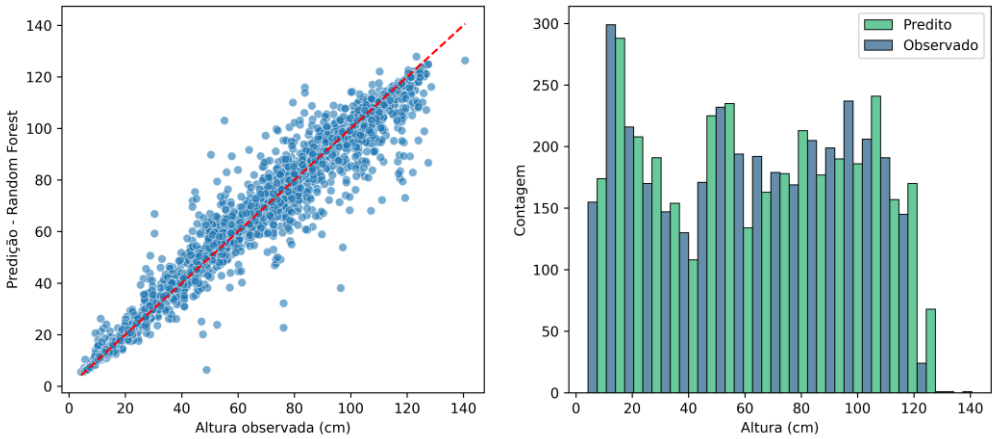


FIGURA 3. Relação entre valores observados de altura de plantas e valores preditos pelo modelo de *machine learning* regressor (*Random Forest*) na etapa de modelagem preditiva.

Após o processo de ajuste dos hiperparâmetros, pôde-se também avaliar as variáveis por meio de sua importância nas predições (Figura 4). A variável dias após emergência é a que mais contribuiu para a performance do algoritmo preditivo, se destacando das demais. Isso está relacionado com a relação fortemente linear durante parte do ciclo de desenvolvimento da planta, na qual na medida em que há avanço dos dias no ciclo, há também o crescimento vertical da planta (PAYERO et al., 2004). A importância de NIR em relação aos índices vegetativos pode ser apontada como uma alternativa ao uso desses, visto que essa banda apresenta forte relação com a planta verde e sadia (GUTIERREZ et al., 2012).

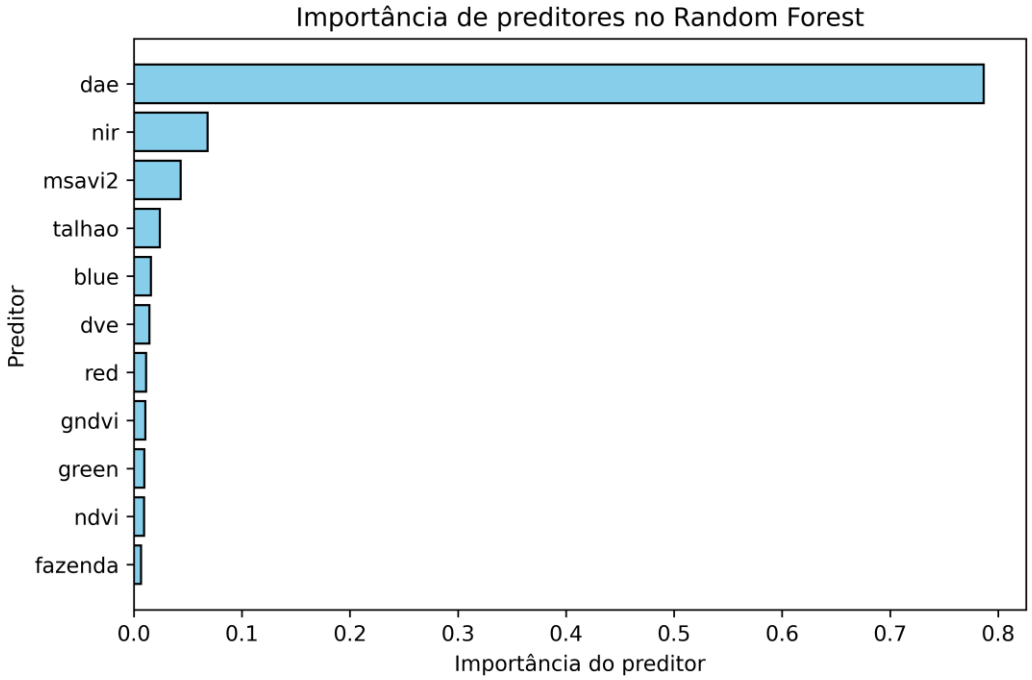


FIGURA 4. Importância das variáveis preditoras no algoritmo de Random Forest regressor usado na predição de altura de plantas de algodão em talhões comerciais.

Predição de altura de plantas: Após validação e teste do modelo, esse foi utilizado em dois talhões que apresentaram uma maior quantidade de dados de monitoramento. Buscou-se fazer uma validação da distribuição espacial das informações, bem como dos dados de leituras em campo, e os pontos mais próximos de dados preditos pelo modelo (i.e., não foram consideradas plantas individuais para comparação, pois as amostras de campo representam uma média de algumas plantas avaliadas em determinado ponto, e os dados de altura foram preditos em grade de 10 metros de resolução espacial). A distribuição espacial dos dados preditos em mapas dos talhões, e associados aos dados de textura de solos por meio de isolinhas da relação Areia:Argila, podem ser observados na Figura 5. A comparação entre dados observados e preditos (amostras de campo e pontos preditos mais próximos ao pontos de leitura) podem ser observados na Figura 6.

Pode-se observar que o talhão A (Figuras 5 A e B) apresenta região relativamente mais arenosa (maior valor de Areia:Argila) na porção mais ao leste, e também que na primeira leitura, as alturas de plantas foram diretamente proporcionais ao teor de areia do talhão (plantas menores em regiões mais arenosas). Já na segunda leitura nota-se uma heterogeneidade de altura de plantas menos acentuada, sendo que plantas com os menores portes foram encontradas também em regiões mais argilosas do

talhão. Isso deve-se também ao manejo do crescimento da planta, que busca homogeneizar, na medida do possível, o desenvolvimento de plantas por meio do regulador de crescimento.

Já o talhão B (Figuras 5 C e D), possui uma marcante região arenosa na sua porção central, como indicado pelas isolinhas e seus (relativamente) altos valores da relação Areia:Argila. Nesse contexto, o porte de plantas foi consistentemente diretamente proporcional ao teor de areia (menores portes sempre nas regiões mais arenosas) durante o ciclo, evidenciando que nesse talhão essa característica ambiental se sobrepõe no desenvolvimento da planta.

De acordo com a Figura 6, nota-se que no talhão A houve uma maior variabilidade entre os dados observados em campo e os preditos. Porém ressalta-se que essa comparação abrange uma determinada área, que por sua vez envolve diversas plantas - portanto em talhões nos quais as amostras foram feitas em regiões mais heterogêneas, isso pode ter contribuído para a menor concordância entre observado x predito. No talhão B foi observada uma menor variabilidade entre predito e observado (especialmente na primeira leitura) - mesmo que esse talhão tenha intensa variabilidade textural, ela encontra-se mais concentrada em determinadas regiões, o que contribui para a melhor performance na predição do crescimento das plantas. Áreas mais arenosas têm menor potencial produtivo devido a fatores físicos, químicos e biológicos que afetam espacial e temporalmente o crescimento vegetal (BASSO et al., 2001), e esse efeito pode ser mais ou menos intenso dependendo do talhão e das condições climáticas da safra. Tal lógica de manejo e efeitos na planta tornam-se complexos para que modelos preditivos consigam "aprender" e fazer predições acuradas sobre a altura de plantas, especialmente quando considera-se os efeitos do manejo e sua interação com os fatores ambientais.

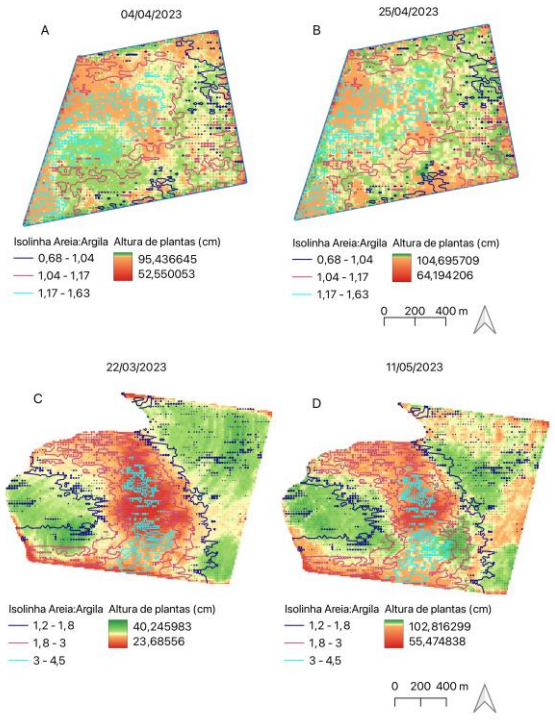


FIGURA 5. Distribuição espacial das predições de altura de plantas de algodão e isolinhas indicando a distribuição da textura de solo, por meio da relação Areia:Argila em três classes nos talhões. Fig. 5A e Fig. 5B: Talhão A nas duas datas; Fig 5C e Fig. 5D: Talhão B nas duas datas.

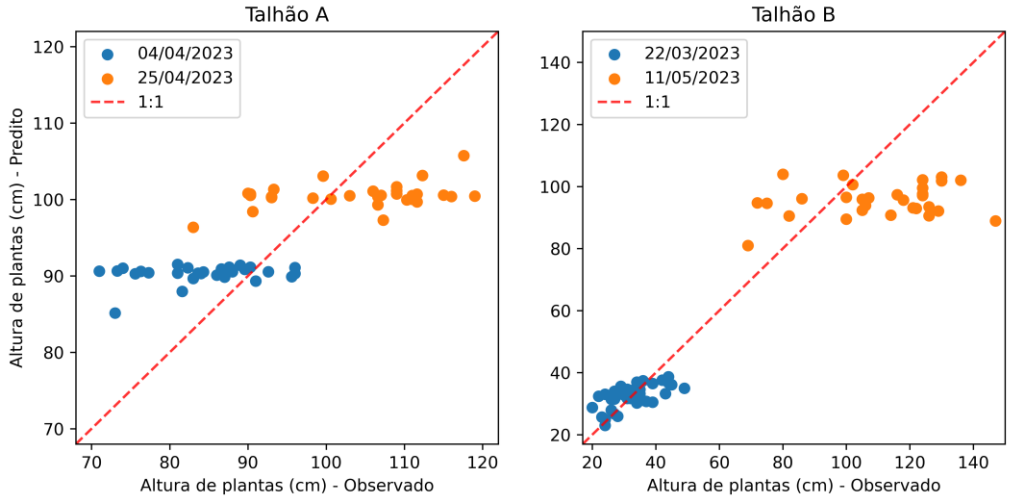


Figura 6. Comparação entre os dados observados em campo e predito pelo algoritmo regressor de altura de plantas de algodão nas duas leituras nos talhões A e B.

Esse estudo fez uma avaliação mais detalhada dos dados preditos em apenas dois dos talhões em uma safra, e não considerou dados meteorológicos. Apesar de o dataset usado para a modelagem preditiva conter elevada quantidade de observações e variabilidade de ocorrências, sabe-se da extensiva necessidade de exemplos para aplicações de *machine learning*, especialmente tratando-se de contexto geral de ampla variabilidade (diversidade de talhões, variação de solos, meteorologia e interação com fatores de manejo). Esse estudo traz como maiores contribuições: (i) a construção de amplo dataset de observações de campo (condições usuais de cultivo em áreas comerciais, visto que condições experimentais dificilmente resultariam na quantidade de observações avaliadas), e (ii) framework que engloba técnicas de modelagem preditiva com resultados satisfatórios, sendo que esse pode ser continuamente aprimorado para melhores predições, especialmente em condições mais críticas, como variabilidade textural, além de permitir a adição de dados meteorológicos, para enriquecer a compreensão do desenvolvimento das plantas.

CONCLUSÃO

O framework proposto no presente trabalho indicou que a modelagem preditiva de altura de plantas utilizando algoritmo de *machine learning* e baseado em dados de sensoriamento remoto e fenologia apresenta boa performance. A futura incorporação de dados meteorológicos e de manejo no framework pode vir a representar melhorias na compatibilidade entre dados simulados e amostrados em campo. Tal abordagem tem performance promissora como ferramenta de auxílio ao manejo do crescimento da cultura do algodão em condições de larga escala.

AGRADECIMENTOS

Agradecemos aos agrônomos e técnicos da Amaggi pela coleta de dados em campo e apoio no delineamento dos experimentos.

REFERÊNCIAS

ANDREA, M.C.S. da.; NASCIMENTO, J.P.F. de O.; MOTA, F.C.M.; OLIVEIRA, R. de S. Predictive framework of plant height in commercial cotton fields using a remote sensing and machine learning approach. **Smart Agricultural Technology**. v.4, p.100154, 2023.

BASSO, B.; RITCHIE, J.T.; PIERCE, F.J.; BRAGA, R.P.; JONES, J.W. Spatial validation of crop models for precision agriculture. **Agricultural Systems**. v.68, p.97-112, 2001.

CONAB Companhia Nacional de Abastecimento - Séries Históricas. 2023; https://www.conab.gov.br/info-agro/safras/serie-historica-das-safras/itemlist/category/898-algodao.

GITELSON, A.A., KUAFMAN, Y.J., MERZLYAK, M.N., Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sens. Environ**. v.58, p.289-298, 1996.

GUTIERREZ, M.; NORTON, R.; THORP, KR.; WANG, G. Association of spectral reflectance indices with plant growth and lint yield in upland cotton. **Crop Sci**. v.161, n.2, p.165-173, 2012.

HERR A.W.; ADAK A.; CARROLL, M.E.; ELANGO D.; KAR S.; LI C.; JONES S.; CARTER A.H.; MURRAY S.C.; PATERSON A.; SANKARAN S.; SINGH A.; SINGH A.K. Unoccupied aerial systems imagery for phenotyping in cotton, maize, soybean, and wheat breeding. **Crop Science**. v.63, p.1722-1749, 2023.

JAMALI, M., BAKHSHANDESH, E., YEGANEH, B., ÖZDOGAN, M. Development of machine learning models for estimating wheat biophysical variables using satellite-based vegetation indices. **Advances in Space Research.** v.73, n.1, p.498-513, 2023.

LOUPPE, G. Understanding Random Forests From Theory to Practice. [Tese de Doutorado, University of Liège]. 2014. doi: 10.48550/arXiv.1407.7502.

MRÓZ, M., SOBIERAJ, A. Comparison of several vegetation indices calculated on the basis of a seasonal spot XS time series, and their suitability for land cover and agricultural crop identification, **Tech. Sci**. v.7, 2004.

PLANT, R.E. Site-specific management: the application of information technology to crop production. **Computers and Electronics in Agriculture**. v.9, p.29-30, 2001.

PAYERO, J.O.; NEALE, C.M.U.; WRIGHT, J.L. Comparison of eleven vegetation indices for estimating plant height of Alfafa and Grass. **Appl. Eng. Agric.** v.20, n.3, p.385-393, 2004.

PLANET. Planet imagery product specifications. Available at https://assets.pl anet.com/docs/Planet_Combined_Imagery_Product_Specs_letter_screen.pdf. 2022.

QGIS.org, 2024. QGIS Geographic Information System. QGIS Association. http://www.qgis.org

SOUZA, H.B., BAIO, F.H.R., NEVES, D.C. Using passive and active multispectral sensors on the correlation with the phenological indices of cotton. **J. Braz. Assoc. Agric. Eng.** v.37, n.4, 782-789, 2017.

TAYLOR, R.; FULTON, J. Sensor-based variable rate application for cotton. Oklahoma Cooperative Extension Service. Oklahoma State University. Stillwater, Oklahoma. p. 1-8, 2010.

TEODORO, P.E., TEODORO, L.P.R., BAIO, F.H.R., et al. Predicting Days to Maturity, Plant Height, and Grain Yield in Soybean: A Machine and Deep Learning Approach Using Multispectral Data. **Remote Sensing.** v.13, p.4632, 2021.

TUCKER, C. J. Red and Photographic Infrared Linear Combinations for Monitoring Vegetation. **Remote Sensing of Environment**. v.8, p. 127-150, 1979.

van DJIK, A.D.J., KOOSTRA, G., KRUJIER, W., de RIDDER, D. Machine Learning in Plant Science and Plant Breeding. **Iscience**, v.24, p.101890, 2021.

WU, J.; CHEN, X-Y.; ZHANG, H.; XIONG, L-D.; LEI, H.; DENG, S-H. Hyperparameter Optimization for Machine Learning Models Based on Bayesian Optimization. **Journal of Electronic Science and Technology**. v.1, p.17, 2019.

XUE, J., SU, B. Significant remote sensing vegetation indices: a review of developments and application, **Hindawi J. Sens**., 2017.

IDENTIFICANDO PADRÕES DE DADOS DE PRODUTIVIDADE E DE FALHAS EM CANAVIAIS COM TÉCNICA DE AGRUPAMENTO

Gabriel Fogaça [1]; Eudocio Rafael Otavio da Silva [2]; José Paulo Molin [3]
[1]Graduando em Eng° Agrônômica. Piracicaba - SP. Lab. de Agricultura de Precisão, Depto. Engenharia de Biossistemas, Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo; [2]Eng° Agrícola e Ambiental, Doutorando. Piracicaba - SP. Lab. de Agricultura de Precisão, Depto. Engenharia de Biossistemas, Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo; [3]Eng° Agrícola, Professor Titular. Piracicaba - SP. Lab. de Agricultura de Precisão, Depto. Engenharia de Biossistemas, Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
A cana-de-açúcar é uma cultura de extrema importância econômica no Brasil. Diversas ferramentas de monitoramento têm sido desenvolvidas para aumentar a produtividade e longevidade dos canaviais. O monitoramento de falhas nas fileiras de cana-de-açúcar destaca-se por ser um problema recorrente e que influencia diretamente na produtividade. Entretanto, o padrão de distribuição e comprimento das falhas em áreas com diferentes potenciais produtivos é pouco discutido. Este estudo teve o objetivo de investigar padrões de ocorrência do comprimento de falhas na fileira de cana-de-açúcar em regiões de potenciais produtivos distintos do canavial, utilizando a técnica de agrupamento. Dados de produtividade obtidos de colheita em canaviais comerciais foram submetidos à análise de cluster, sendo agrupados de acordo com o potencial produtivo de cada região. Para cada cluster, foram verificadas as ocorrências e comprimentos de falhas na fileira da cultura. Os resultados mostraram que nem sempre as regiões de menor potencial produtivo apresentaram a maior média do comprimento de falhas, mas sempre apresentaram a maior área de falhas. Os resultados também evidenciaram um comportamento padrão na curva de distribuição das falhas para todos os clusters analisados.

PALAVRAS-CHAVE: cana-de-açúcar; k-médias; sensoriamento remoto

ABSTRACT
Sugarcane is a crop of extreme economic importance in Brazil. Several monitoring tools have been developed to increase the yield and longevity of sugarcane fields. Monitoring failures in sugarcane rows stands out as a recurring problem that directly influences the yield of sugarcane fields. However, the distribution pattern and length of gaps in areas with different productive potentials is little discussed. This study aimed to investigate patterns of occurrence of the length of gaps in the sugarcane row in regions with different production potentials than the sugarcane field, using the clustering technique. Yield data obtained from harvesting in commercial sugarcane fields were subjected to cluster analysis, being grouped according to the productive potential of each region. For each cluster, the occurrences and lengths of gaps in the crop row were verified. The results showed that the regions with the lowest productive potential did not always have the highest average gaps length, but they always presented the largest gaps area. The results also showed a standard behavior in the gap distribution curve for all clusters analyzed.

KEYWORDS: ;

INTRODUÇÃO

O Brasil é o maior produtor mundial da cultura da cana-de-açúcar. De acordo com a Companhia Nacional de Abastecimento (CONAB), na safra 2022/23 o Brasil produziu um total de 610.131,4 mil toneladas de cana-de-açúcar (CONAB, 2023). Dada a importância da cultura, diversas técnicas de manejo são adotadas nas lavouras de cana, dentre elas, a colheita mecanizada. Apesar dos seus diversos benefícios, ainda prevalecem problemas como a compactação do solo e degradação das plantas nas fileiras ocasionados pelo tráfego de máquinas (LUZ et al., 2023). Os danos causados pelo tráfego de máquinas na colheita em conjunto com fatores genéticos, fisiológicos e climáticos podem degradar as plantas, afetando a brotação (SERAFIM et al., 2013). O não desenvolvimento da cana-planta ou cana-soca geram falhas nas fileiras de cana-de-açúcar.

Stolf (1986) realizou um dos primeiros estudos referentes a falhas e propôs que elas seriam equivalentes à distância entre duas plantas na fileira. A partir de experimentações, verificou que quanto maior a porcentagem de falhas no canavial, maior a redução da produtividade de cana. Décadas depois, foi verificado em Maldaner et al. (2024) que a densidade de plantas afeta a produtividade da cana, considerando regiões de produtividades distintas e que a densidade populacional diminuiu ao longo do tempo à medida que o povoamento se deteriorava. Logo, verifica-se que são relativamente novos na literatura os estudos que apresentam as relações da falha e da produtividade em alta resolução espacial. A principal decisão derivada da ocorrência de falhas é a de reforma do canavial. Entretanto, não se faz distinção, dentro de um mesmo talhão, entre os padrões de distribuição e comprimento de falhas em regiões com diferentes potenciais produtivos, a fim de compreender se a decisão de gestão dessas falhas deve ser a mesma independente da produção observada/esperada em uma área. Dessa forma, se faz necessário identificar padrões espaciais das falhas em diferentes contextos e cenários na lavoura, considerando o potencial produtivo da região onde elas estão presentes.

OBJETIVOS

O objetivo deste estudo foi investigar padrões de ocorrência do comprimento de falhas na fileira em regiões de potenciais produtivos distintos do canavial, utilizando a técnica de agrupamento.

MATERIAL E MÉTODOS

O estudo foi realizado em área comercial de cana-de-açúcar, localizada no estado de São Paulo, Brasil. A região possui clima tropical de inverno seco, caracterizada como Aw, de acordo com a classificação climática de Köppen-Geiger. A área total da lavoura abrange 42,82 ha, em que os talhões 1 e 2 possuem 23,03 e 23,79 ha, respectivamente. A variedade de cana-de-açúcar cultivada nos talhões é a RB966928, colhida em terceiro corte.

Os dados de produtividade foram coletados a partir de um sistema de sensores comerciais (Solinftec, Araçatuba, São Paulo, Brasil) que toma como base a pressão de propulsão necessária para picar a cana-de-açúcar no motor do sistema picador (MALDANER et al., 2022). A colhedora, de uma fileira, é equipada com um receptor Sistema Global de Navegação por Satélite (GNSS) de posicionamento acurado. Após a obtenção dos dados de colheita, os conjuntos de dados foram submetidos a filtragem, visando remover dados errôneos e discrepantes.

A coleta de dados de falhas na fileira da cana por meio de Veículo Aéreo Não Tripulado (UAV) foi realizada por uma empresa de serviços contratada para esse fim. Nesse método, o mosaico de imagens foi gerado a partir de voo do UAV, modelo eBee equipado com um sensor RGB S.O.D.A com resolução espacial de 0,03 m e as geometrias de linha, correspondente às fileiras de cana, foram reconstituídas. O voo foi realizado baseado na altura da planta, quando a planta atingiu entre 0,60 a 1,20 m de crescimento no início da safra, na visibilidade da entrelinha e fase de perfilhamento da cana-soca. Posteriormente, foram obtidas as falhas na fileira de cana, utilizando-se como critério a

identificação de espaçamentos maiores do que 0,58 m entre as plantas, com base nos dados extraídos do mosaico de imagens gerado pelo UAV.

Para realizar a análise dos padrões de dados de produtividade e de falhas, foram gerados três agrupamentos (do inglês, *clusters*) classificados em alta, média e baixa produtividade. A análise de agrupamento tem o intuito de agrupar dados semelhantes em clusters, tornando-se uma ferramenta altamente eficaz para a análise de dados (GÉRON, 2021). Nesse estudo, os clusters foram gerados por meio do método fuzzy k-médias. O método k-médias classifica os dados em grupos. A partir do momento em que é informado o número de classes desejadas, são calculados os centróides de cada grupo. Posteriormente, os dados são realocados conforme a similaridade entre eles, através do cálculo entre a distância de cada dado em relação aos centróides definidos. O processo se repete até que os clusters não mudem entre as iterações. O método fuzzy k-médias possui processo semelhante ao k-médias. No entanto, no método fuzzy k-médias todos os dados afetam o cálculo dos centróides, pois no algoritmo, os dados possuem um grau de pertencimento, que é inversamente proporcional à distância desse ponto ao centróide do cluster (HOT & POPOVI?-BUGARIN, 2015). Para isto, utilizou-se os dados de produtividade filtrados de cada talhão através do plugin Smart-map (PEREIRA et al., 2022) inserido no Sistema de Informação Geográfico (SIG) QGIS v. 3.28.14. Foram definidos os parâmetros Fuzzy Performance Index (FPI), Normalized Classification Entropy (NCE) e k igual a três (PEREIRA et al., 2022). Esse agrupamento permitiu a separação em três regiões de diferentes potenciais produtivos da cana. Após a criação dos clusters, foi usada a função de 'Interseção' do SIG QGIS, para identificar os dados de falhas correspondentes a cada cluster.

Para cada cluster em cada talhão, foram obtidas a quantidade de falhas (espaçamento entre plantas), os valores do comprimento de falha na fileira e a porcentagem de falhas no campo (MOLIN & VEIGA, 2016). Os dados de produtividade e de falhas dos clusters em cada talhão foram submetidos à estatística descritiva, em que foram obtidos os seus valores máximos, mínimos, médios, desvio padrão (DP) e coeficiente de variação (CV%). A comparação da produtividade e do comprimento das falhas relacionadas aos clusters foi avaliada por meio da análise de variância (ANOVA) e, quando encontradas diferenças significativas, os valores médios foram comparados pelo teste Tukey a 5% de probabilidade ($p<0,05$).

RESULTADOS E DISCUSSÃO

A Figura 1 exibe os clusters gerados de acordo com os valores de produtividade de cada talhão, sendo classificados em alta, média e baixa produtividade (Figura 1).

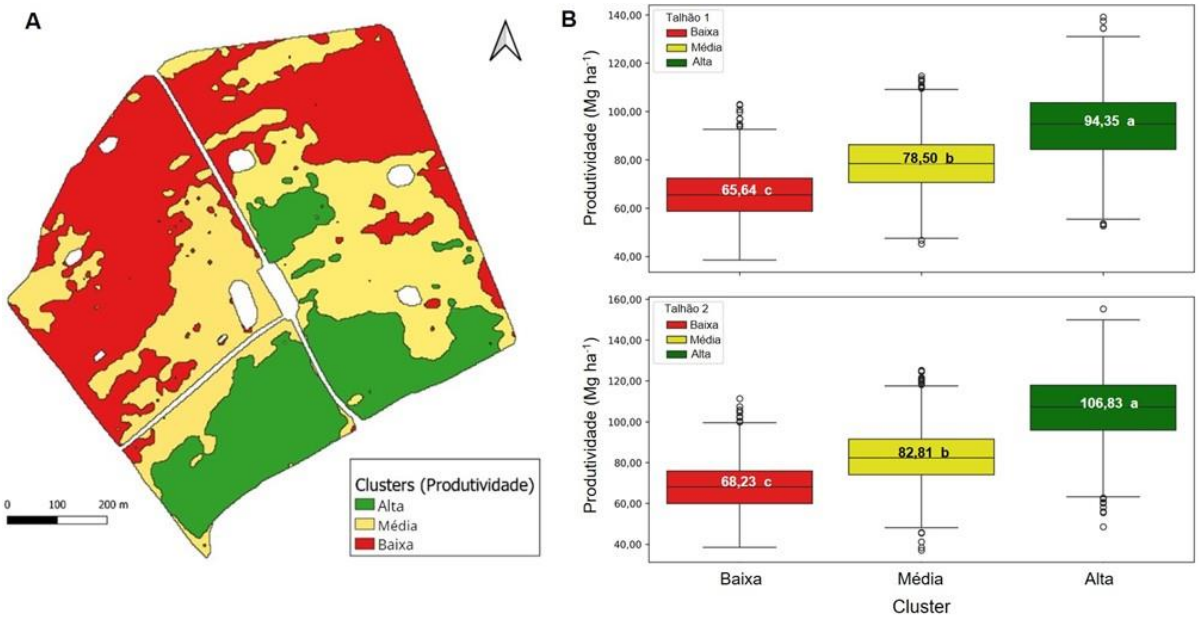


FIGURA 1. Clusters de produtividade obtidos nos talhões 1 e 2 (A) e comparação da produtividade (em Mg ha-1) em cada cluster (B). Para cada talhão, letras minúsculas diferentes dentro da caixa indicam diferença significativa entre a produtividade dos clusters (teste de Tukey; p<0,05).

A partir da Tabela 1, é possível observar os resultados das análises dos dados de produtividade de cada cluster.

TABELA 1. Análise estatística dos dados de produtividade nos clusters para os talhões 1 e 2.

Talhão	Cluster	Produtividade média (Mg ha^{-1})	Valor mínimo (Mg ha^{-1})	Valor máximo (Mg ha-1)	Desvio Padrão	Coeficiente de variação (%)
1	Alta	94,35	52,64	139,08	14,65	15,53
	Média	78,50	45,21	114,65	11,39	14,51
	Baixa	65,64	38,52	102,99	9,89	15,07
2	Alta	106,83	48,61	155,25	16,36	15,31
	Média	82,81	37,12	125,24	12,89	15,56
	Baixa	68,23	38,42	111,27	11,15	16,34

Os resultados da análise estatística da produtividade mostram as diferenças entre os clusters dos talhões 1 e 2. Por meio do teste de comparação de médias de Tukey, observou-se que os valores médios de produtividade entre os clusters foram significativamente diferentes (p<0,05). Dessa maneira, o agrupamento se mostrou eficaz na distinção de zonas de produção de cana.

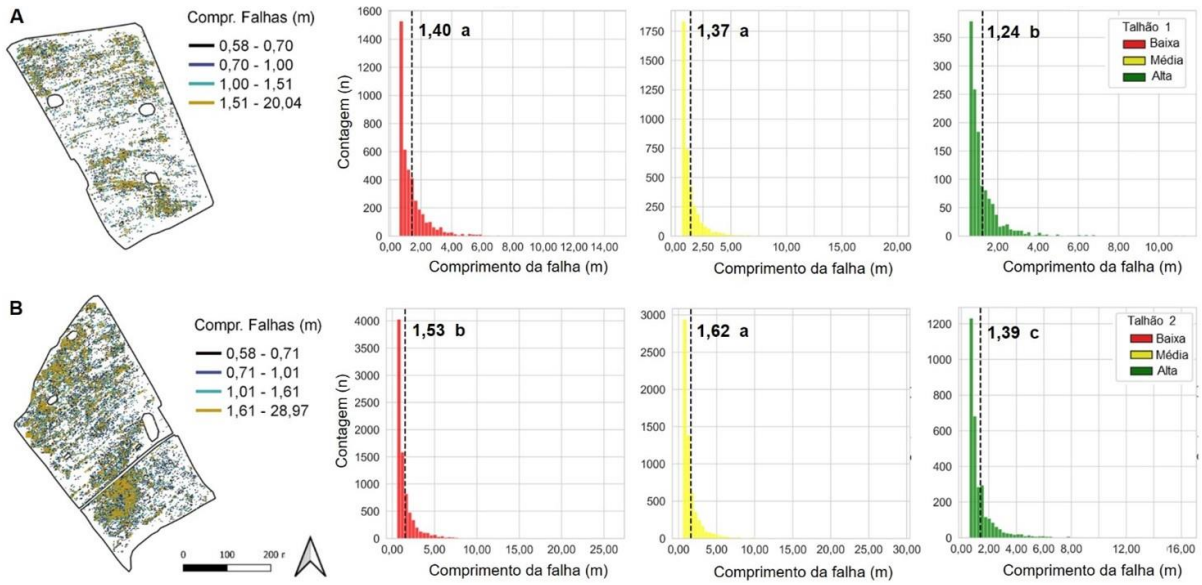


FIGURA 2. Distribuição espacial dos dados de falhas na fileira de cana coletados obtidos por UAV e comparação do comprimento de falhas (em m) em cada cluster nos talhões 1 (A) e 2 (B). A linha vertical tracejada indica o valor médio do comprimento de falha no histograma. Para cada talhão, letras minúsculas diferentes indicam diferença significativa entre o comprimento de falhas dos clusters (teste de Tukey; $p<0,05$).

A Figura 2 ilustra a distribuição espacial das falhas nos talhões 1 e 2 e compara os comprimentos de falhas em cada cluster. Observa-se que os comprimentos de falhas variaram entre 0,58 e 20,04 m no talhão 1 e entre 0,58 e 28,97 m no talhão 2. A análise das curvas de distribuição mostrou um padrão de comportamento para as falhas em que mesmo separando-as em clusters dentro do talhão, apresentam uma curva exponencial decrescente, independente da ocorrência de falha ser em uma região de alto ou baixo potencial produtivo. Sendo assim, observou-se que à medida que o comprimento de falha aumenta, sua ocorrência tende a diminuir. Este comportamento da curva corrobora com o que foi discutido em Stolf (1986), que em seu experimento para avaliar falhas nas fileiras de cana também foi observada a diminuição da ocorrência de falhas à medida que os seus comprimentos aumentaram.

A Tabela 2 mostra a análise estatística dos dados de comprimento de falhas nos clusters para os talhões 1 e 2. A análise dos resultados revela que o comprimento médio das falhas é consistente, independentemente do potencial produtivo da área. Isso sugere que o tamanho médio das falhas é uniforme em diferentes zonas de produção. O fator que mais influenciou a produtividade foi a quantidade total de falhas, ou seja, falhas longas são raras, mas seu impacto pode ser substancial ao totalizar o seu comprimento na zona de produção gerada (cluster). Portanto, além do número de falhas e do comprimento individual de cada uma, é crucial para os gestores o conhecimento da zona de produção em que estão localizadas estas falhas. Por exemplo, as áreas de baixo potencial produtivo tiveram um comprimento total de falhas 300% maior do que as áreas de alto potencial, mesmo com um comprimento médio de falhas semelhante, variando entre 1,24 m e 1,62 m por falha.

TABELA 2. Análise estatística dos dados de comprimento de falhas nos clusters para os talhões 1 e 2.

Talhão	Cluster	Média do comprimento de falha (m)	Valor mínimo (m)	Valor máximo (m)	Desvio Padrão	Coeficiente de variação (%)	Soma total de falhas (m)	Área de falhas (ha)	Área com falhas (%)
1	Alta	1,24	0,58	11,31	0,91	73,39	1.607,09	0,24	1,05
	Média	1,37	0,58	20,04	1,23	89,78	5.390,20	0,81	3,51

	Baixa	1,40	0,59	14,70	1,09	77,86	5.896,65	0,88	3,84
	Alta	1,39	0,58	16,30	1,26	90,65	4.389,40	0,66	2,76
2	Média	1,62	0,58	28,97	1,68	104,35	10.011,91	1,50	6,31
	Baixa	1,53	0,58	26,13	1,55	101,31	12.469,62	1,87	7,86

No talhão 2, o cluster de alta produtividade também apresentou a menor média de comprimento de falhas entre os demais clusters. No entanto, o cluster que apresentou a menor média de comprimento de falhas do talhão 2 foi o cluster de média produtividade, evidenciando que nem sempre o cluster de baixa produtividade apresentou a menor média de comprimento de falhas. Isto também é evidenciado pelo teste de comparação de médias de Tukey, no qual foi observado que o comprimento médio de falhas para os clusters de média e baixa produtividade não apresentaram diferenças significativas a 95% de confiança ($p<0,05$). Entretanto, é necessário verificar mais do que os valores médios obtidos pelas variáveis em cada cluster. Logo, ao analisar os valores da soma total de falhas (m), área de falhas (ha) e área com falhas (%) para cada cluster em cada talhão, foi observado que o cluster de alta produtividade de cana-de-açúcar, sempre apresentou os menores valores desses parâmetros enquanto o cluster de baixa produtividade apresentaram os maiores valores.

É importante ressaltar que a relação entre a quantidade total de falhas e a produtividade não é linear. Uma falha de mesmo comprimento em áreas com diferentes potenciais produtivos resulta em perdas de produtividade variadas, sendo mais pronunciadas em áreas de maior potencial. Embora a distribuição espacial do comprimento das falhas seja semelhante em áreas de alto e baixo potencial produtivo, a ocorrência total de falhas difere. Isso suscita a questão: a maior ocorrência de falhas é consequência de uma região de baixo potencial produtivo, ou uma região de baixo potencial produtivo é consequência da maior ocorrência de falhas? Pesquisas futuras podem investigar essa questão, pois a resposta tem implicações significativas na interpretação dos dados de ocorrência de falhas e sua relação com diferentes áreas de produção, influenciando (e possivelmente alterando) as decisões dos gestores a partir disso.

Os resultados obtidos neste estudo indicam que a identificação de padrões de produtividade e de falhas, através do método *fuzzy* k-médias, possui potencial para ser utilizada como uma camada de informação na tomada de decisões, como, por exemplo, na identificação de regiões no canavial que possam ser reformadas, visto que os parâmetros geralmente considerados para isso são os valores de produtividade obtidos na safra e a porcentagem de falhas determinadas através de pequenas amostras aleatórias coletadas dentro do campo, dificultando a realização de uma caracterização confiável da variabilidade das falhas existentes nos canaviais (MALDANER et al. 2021). Assim, a geração desses agrupamentos se mostra promissora para a gestão do canavial.

CONCLUSÃO

O agrupamento *fuzzy* k-médias mostrou que as falhas de maior comprimento não estão necessariamente situadas nos locais de menor produtividade de cana-de-açúcar. Ao contrário, o fator que se observou mais afetar a produtividade dos talhões analisados foi o comprimento total de falhas, que foi mais observado em locais de menor produtividade, apesar do comprimento médio das falhas ter sido similar ao das zonas de média e alta produtividade. Os resultados também mostram um padrão no comportamento das curvas de distribuição das falhas, sendo que em todos os clusters a curva de distribuição se apresentou de forma exponencial decrescente. Conclui-se que a identificação de padrões de falhas nas regiões de potenciais produtivos distintos por meio da técnica de agrupamento é uma potencial abordagem para a tomada de decisão no canavial.

AGRADECIMENTOS

À Solinftec pelo suporte na obtenção dos dados.

REFERÊNCIAS

COMPANHIA NACIONAL DE ABASTECIMENTO (CONAB). **Acompanhamento da safra brasileira de cana-de-açúcar**, v. 10, safra 2022/23, n. 4, quarto levantamento, abril 2023.

GÉRON, A.; **Mãos à obra: aprendizado de máquina com Scikit-Learn, Keras & TensorFlow: Conceitos, ferramentas e técnicas para a construção de sistemas inteligentes**. 2ª ed., Alta Books, 2021.

HOT, E; POPOVI?-BUGARIN, V. Soil data clustering by using K-means and fuzzy K-means algorithm. **23rd Telecommunications Forum Telfor (TELFOR)** IEEE, p. 890-893, 2015.

LUZ, F. B.; GONZAGA, L. C.; CASTIONI, G. A. F.; LIMA, R. P., CARVALHO, J. L. N.; CHERUBIN, M. R. Controlled traffic farming maintains soil physical functionality in sugarcane fields. **Geoderma**, v. 432, 116427, 2023.

MALDANER, L. F.; CANATA, T. F.; MOLIN, J. P. An approach to sugarcane yield estimation using sensors in the harvester and zigbee technology. **Sugar Tech**, v. 24, n. 3, p. 813-821, 2022.

MALDANER, L. F.; MOLIN, J. P.; SILVA, E. R. O. Spatial-Temporal Analysis to Investigate the Influence of in-Row Plant Spacing on the Sugarcane Yield. **Sugar Tech**, v. 26, p. 194-206, 2024.

MOLIN, J. P.; VEIGA, J. P. S. Spatial variability of sugarcane row gaps: measurement and mapping. **Ciência e Agrotecnologia**, v. 40, p. 347-355, 2016.

PEREIRA, G. W.; VALENTE, D. S. M.; QUEIROZ, D. M. D.; COELHO, A. L. D. F.; COSTA, M. M.; GRIFT, T. Smart-map: An open-source QGIS plugin for digital mapping using machine learning techniques and ordinary kriging. **Agronomy**, v. 12, n. 6, 1350, 2022.

SERAFIM, L. G. F.; STOLF, R.; SILVA, J. R.; SILVA, L. C. F.; MANIERO, M. A.; BASSINELLO, A. I. Influência do plantio mecanizado no índice de brotação da cana de-açúcar. **STAB**, v. 31, p. 22-25, 2013.

STOLF, R. Metodologia de avaliação de falhas nas linhas de cana-de-açúcar. **STAB**, v. 4, n. 6, p, 22-36, 1986.

DESEMPENHO DE MÉTODOS DE FILTRAGEM PARA DADOS DE PRODUTIVIDADE EM CANAVIAIS UTILIZANDO DADOS DISCREPANTES ARTIFICIAIS

Yuri de Lacerda Barbosa [1]; Eudocio Rafael Otavio da Silva [2]; Marcelo Chan Fu Wei [3]; José Paulo Molin [4]

[1]Graduando em Eng° Agronômica. Avenida Pádua Dias, 11, 13418-900, Piracicaba, São Paulo, Brasil. Universidade de São Paulo - Escola Superior de Agricultura 'Luiz de Queiroz'; [2]Eng° Agrícola e Ambiental. Avenida Pádua Dias, 11, 13418-900, Piracicaba, São Paulo, Brasil. Universidade de São Paulo - Escola Superior de Agricultura 'Luiz de Queiroz'; [3]Eng° Agrônomo, Doutorando. Avenida Pádua Dias, 11, 13418-900, Piracicaba, São Paulo, Brasil. Universidade de São Paulo - Escola Superior de Agricultura 'Luiz de Queiroz'; [4]Engº Agrícola, Professor Titular. Avenida Pádua Dias, 11, 13418-900, Piracicaba, São Paulo, Brasil. Universidade de São Paulo - Escola Superior de Agricultura 'Luiz de Queiroz'

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

O mapeamento da produtividade vem adquirindo importância no setor canavieiro. Como em outras culturas, os dados coletados devem ser submetidos a processos de detecção e remoção de erros. Neste trabalho avalia-se o desempenho de métodos de filtragem para dados de produtividade em canaviais utilizando dados discrepantes artificiais. O conjunto de dados é proveniente de quatro talhões comerciais de cana-de-açúcar obtidos na colheita de 2021. Para isto, foram inseridos dados discrepantes artificias aos dados brutos de maneira aleatória. As filtragens são baseadas em cinco métodos estatísticos existentes: Z-score, desvio padrão, intervalo interquartílico, critério de Chauvenet além de um baseado em análise global e local anisotrópica e isotrópica, o aplicativo MapFilter 2.0. Os dados filtrados foram submetidos a estatística descritiva para visualização e os métodos foram comparados baseados no seu desempenho de detecção de dados discrepantes artificiais. O MapFilter 2.0 teve o melhor desempenho em identificar os dados discrepantes artificiais seguido pelo método de Chauvenet. Os outros métodos apresentaram um desempenho igual e inferior a 50,00% na detecção de dados discrepantes. Esses desempenhos refletiram fielmente o resultado da filtragem dos dados brutos originais. Mais estudos são necessários para determinar se todos os dados filtrados eram de fato discrepantes com a realidade.

PALAVRAS-CHAVE: Mapfilter; Sensores de colheita; Chauvenet

ABSTRACT

Yield mapping has been gaining importance in the sugarcane sector. As in other crops, the collected data must undergo processes of error detection and removal. In this study, the performance of filtering methods for yield data in sugarcane fields using artificial outliers is evaluated. The dataset comes from four commercial sugarcane plots obtained during the 2021 harvest. For this purpose, artificial outliers were inserted into the raw data randomly. Filtering is based on five existing statistical methods: Z-score, standard deviation, interquartile range, Chauvenet's criterion, as well as one based on global and local anisotropic and isotropic analysis, the MapFilter 2.0 application. The filtered data were subjected to descriptive statistics for visualization, and the methods were compared based on their performance in detecting artificial outliers. MapFilter 2.0 achieved the best performance in identifying artificial outliers followed by Chauvenet's method. The other methods showed performance equal to or less than 50.00% in detecting outliers. These performances accurately reflected the result of filtering the original raw data. Further studies are needed to determine if all the filtered data were indeed outliers in reality.

KEYWORDS: ;

INTRODUÇÃO

Os mapas de produtividade são uma importante ferramenta de agricultura de precisão, no qual reflete respostas das plantas às práticas de manejo, permite realizar caracterização qualitativa e quantitativa da produção (LUND et al., 2016), identificar variações e investigar fatores que as afetam (HIGGINS et al., 2019), e auxilia na tomada de decisão e implementação de estratégias de manejo específicas para cada local (MONTEIRO et al., 2021). A implementação de sistemas automatizados em colhedoras para o monitoramento da produtividade resulta na coleta de uma grande quantidade de dados. No entanto, é importante exercer cuidado ao utilizar esses dados, pois nem todos os pontos registrados refletem a produtividade real. Dados discrepantes (em inglês, *outliers*) são aqueles que diferem das outras observações do mesmo conjunto de dados e podem ser atribuídos a erros de medição ou registro, como os causados pelo tempo de demora entre o corte e o enchimento da colhedora, erros de amostragem e há casos de valores excepcionais, porém verdadeiros (LYLE et. al., 2014; MALDANER et. al., 2021). Logo, cabe ao analista de dados o desafio de remover esses dados, visto que podem distorcer a análise, ou mantê-los pois podem representar um fenômeno que esteja acontecendo no campo (SMITI, 2020). Frente o desafio da ausência de uma referência que defina o que é um dado discrepante, alguns estudos, como o de Liu et al. (2021), tem inserido dados discrepantes artificiais, que são valores conhecidos e inseridos pelo usuário do arquivo de dados, no conjunto de dados.

Não existe, atualmente, um consenso sobre qual o melhor método a ser utilizado na filtragem de dados oriundos de cana-de-açúcar.

OBJETIVOS

Avaliar o desempenho de métodos de filtragem para dados de produtividade em canaviais utilizando dados discrepantes artificiais, tendo como objetivos específicos i) realizar a filtragem de dados de produtividade de cana-de-açúcar utilizando cinco diferentes métodos de filtragem de dados e ii) comparar seus desempenhos estatisticamente e espacialmente entre si.

MATERIAL E MÉTODOS

O conjunto de dados é proveniente da colheita em 2021 de quatro talhões (23,1; 23,8; 30,1 e 12,9 ha) cultivados com a variedade de cana-de-açúcar RB966928 em solo classificado como Latossolo Vermelho Álico localizados no estado de São Paulo, Brasil. As colhedoras, todas de fileira única, estavam equipadas com Sistema Global de Navegação por Satélite (GNSS) e com sistema de sensor comercial (Solinftec, Araçatuba, Brasil), como o usado por Maldaner; Canata e Molin (2022) na avaliação da acurácia de previsão da massa de cana-de-açúcar por um sensor de pressão de propulsão instalado no tambor picador de uma colhedora. A lavoura estava no seu terceiro corte e seu estado de maturação precoce. Esses dados estavam divididos de acordo com suas respectivas áreas.

O conjunto de dados original de cada talhão foi contaminado por dados discrepantes artificiais, baseados em Liu et al. (2021). A inserção desses dados foi realizada afim de conferir o desempenho dos filtros usados, já que no banco de dados original nem sempre é possível julgar se o dado filtrado era ou não representativo da realidade. Os dados foram inseridos conforme a equação 1.

$$AO = Z + OM * Z \quad \text{Eq. (51)} \tag{1}$$

em que: AO - valor periférico artificial; Z - valor original de um elemento; e OM - valor de magnitude do dado discrepante, que podem ser: ±0,01, ±0,05, ±0,10, ±0,50, ±0,80, ±1,00.

A seleção de Z, ou seja, dos valores das linhas no banco de dados foi aleatória. Após filtrar com cada método os dados originais contaminados com os dados discrepantes artificiais, foi então calculado, a partir da quantidade de dados "AO" remanescentes, o desempenho na detecção de outliers de cada método. Esta etapa foi realizada em ambiente virtual *JupyterLab*, utilizando a linguagem de programação Python v. 3.10.5 (KLUYVER et al., 2016).

Os métodos de filtragem de dados selecionados foram: Z-Score (método 1) (HODGE & AUSTIN, 2004), MapFilter 2.0 (método 2) (MALDANER et al., 2021), desvio padrão (método 3) (BECK & KÜHN, 2017), intervalo interquartílico (método 4) (JEONG et al., 2017) e Critério de Chauvenet (método 5) (LIN & SHERMAN, 2007). O método 1 utiliza os cálculos da média e desvio padrão dos dados medidos como definição de outlier. Se a diferença entre aquele dado e a média for maior que X vezes o desvio padrão, então aquela medição é definida como outlier (HODGE & AUSTIN, 2004). O método 2 é um método robusto de análise de dados de alta densidade, processado através do programa Mapfilter 2.0. Neste filtro são realizadas análise global dos dados e uma análise local isotrópica e anisotrópica levando em consideração os valores da vizinhança. A análise global remove os dados que estão fora do limite superior e inferior, e estes limites são calculados conforme as equações 2 e 3.

Limite superior = mediana + (Limite de variação (%) * mediana) (2)

Limite inferior = mediana - (Limite de variação (%) * mediana) (3)

em que: mediana - calculada a partir do parâmetro que está sendo filtrado; e limite de variação - valor em porcentagem selecionado dentro do programa.

A análise local anisotrópica é feita calculando uma mediana a partir da seleção de todos os pontos que estão dentro da mesma fileira, e a partir dessa mediana calcula-se os limites superiores e inferiores locais para cada fileira. Após essa filtragem local por linhas, é feita uma segunda filtragem, a isotrópica, onde define-se o valor do raio de dependência espacial para cada ponto. A partir disso, é calculada uma nova mediana, novo limite superior e inferior local (repetindo a mesma fórmula anterior) considerando todos os pontos dentro do raio de cada ponto analisado. Os pontos são removidos caso estejam fora desses novos limites calculados.

O método 3 é calculado a partir da equação 4:

desvio padrão:

$$\sqrt{\frac{\sum(xi - x)^2}{n}} \quad \text{Eq. (52)}$$

(4)

em que: xi - valor observado; x - média daquele conjunto de dados; e n - número de dados daquele conjunto.

A partir disso foram criados dois limites, um superior (média + desvio padrão) e um inferior (média - desvio padrão), para definir o limiar do que é ou não dados discrepantes (BECK & KÜHN, 2017).

O método 4 utiliza valores estimados por métodos de regressão, definindo seus valores limites de aceitação ou rejeição do valor medido (JEONG et al., 2017). Os limites superior e inferior nesse método são definidos conforme as equações 5 e 6.

limite superior = q3 + 1,5 * iqr (5)

limite inferior = q1 - 1,5 * iqr (6)

em que: q1 - valores que se encontram nos primeiros 25% dos dados ordenados (primeiro quartil); q3 - valores que estão nos últimos 25% dos dados ordenados (terceiro quartil);

O valor de iqr que é definido conforme a equação 7.

iqr = q3 - q1 (7)

O método 5 utiliza o desvio padrão, a média e o tamanho conhecido de uma amostra de dados para definir se um valor medido é aceitável ou não (LIN & SHERMAN, 2007). Este método pode ser definido de a acordo com a equação 8.

Se

$$\frac{|xi - u|}{y}$$ Eq. (53)

> R, rejeite

$$xi$$ Eq. (54)

(8)

em que: R - valor tabelado pelo critério de Chauvenet para a quantidade de amostras utilizadas; xi - tamanho conhecido de uma amostra; u - média; e y - desvio padrão.

A filtragem dos dados foi realizada no ambiente R (R CORE TEAM, 2023), com exceção do método 2, na qual possui interface própria. Foi realizado cálculo estatístico para os dados filtrados indicando sua média, desvio padrão (DP), coeficiente de variação (CV), valor máximo e mínimo para cada método e área estudada. Os dados filtrados foram inseridos no Sistema de Informação Geográfico QGIS 3.28.15 e, então, seus respectivos mapas foram gerados.

RESULTADOS E DISCUSSÃO

A estatística dos dados está descrita na Tabela 1 e a partir dela é possível observar que os dados brutos de todas as áreas apresentam valores mínimos iguais a zero, valores máximos elevados para a cultura da cana-de-açúcar, chegando a valores superiores a 600,00 Mg ha $^{-1}$ e elevados coeficientes de variação. O cenário mudou após esses dados serem filtrados e seu comportamento variou de acordo com cada método.

O método de filtragem que apresentou os maiores valores de coeficiente de variação foi o método 4, seguido do método 1. O método 4 utilizou os maiores valores de limite superior e os menores de limite inferior, resultando e classificando menores valores determinados como discrepantes. Um comportamento que se pode observar é de que quanto maior a porcentagem de remoção de dados por cada método, menor o coeficiente de variação resultante da filtragem do mesmo.

TABELA 1. Estatística descritiva para os dados brutos e filtrados de cada área nos diferentes métodos de filtragem.

Área 1						
		Método				
Parâmetros	Brutos	1	2	3	4	5
n	19807	14145	8870	12148	14490	9875
% de remoção	0,00	28,59	55,22	38,67	26,84	50,14
Máximo	333,88	129,69	92,74	102,62	138,12	90,60
Mínimo	0,00	25,96	49,97	28,92	16,68	40,79
Média	65,69	78,78	73,31	73,54	79,57	70,60
DP	36,94	20,63	10,09	15,70	22,07	11,84
CV	56,23	26,19	13,76	21,35	27,73	16,77
Área 2						
n	21711	15752	8620	12975	16141	10562
% de remoção	0,00	27,45	60,30	40,24	25,66	51,35
Máximo	670,12	141,55	95,60	109,91	157,35	97,07
Mínimo	0,00	21,44	51,56	31,10	5,29	43,89
Média	70,46	83,39	74,05	76,42	84,35	73,34
DP	39,46	24,42	10,63	17,76	26,16	13,30
CV	56,00	29,28	14,36	23,25	31,01	18,13
Área 3						
n	24949	17892	11226	15190	18416	11886
% de remoção	0,00	28,29	55,00	39,12	26,19	52,36
Máximo	528,02	132,03	99,24	106,95	145,78	94,52
Mínimo	0,00	33,10	53,49	30,69	19,43	43,11
Média	68,77	84,59	78,98	78,67	85,05	74,71
DP	38,18	20,39	11,00	16,42	22,10	12,45
CV	55,53	24,10	13,93	20,87	25,99	16,67
Área 4						
n	14071	8566	5265	7394	8710	5596
% de remoção	0,00	39,12	62,58	47,45	38,10	60,23
Máximo	649,69	139,70	100,66	109,94	149,50	96,19
Mínimo	0,00	31,36	54,32	25,72	21,20	39,14
Média	67,65	87,33	81,72	81,67	87,61	76,19
DP	42,33	20,74	10,91	17,11	21,88	13,43
CV	62,58	23,75	13,35	20,95	24,98	17,63

n: número de observações; % de remoção: porcentagem de dados removidos; DP: Desvio padrão; CV: Coeficiente de variação.

Na Figura 1 é possível visualizar espacialmente o alto coeficiente de variação dos dados brutos como indicado na Tabela 1.

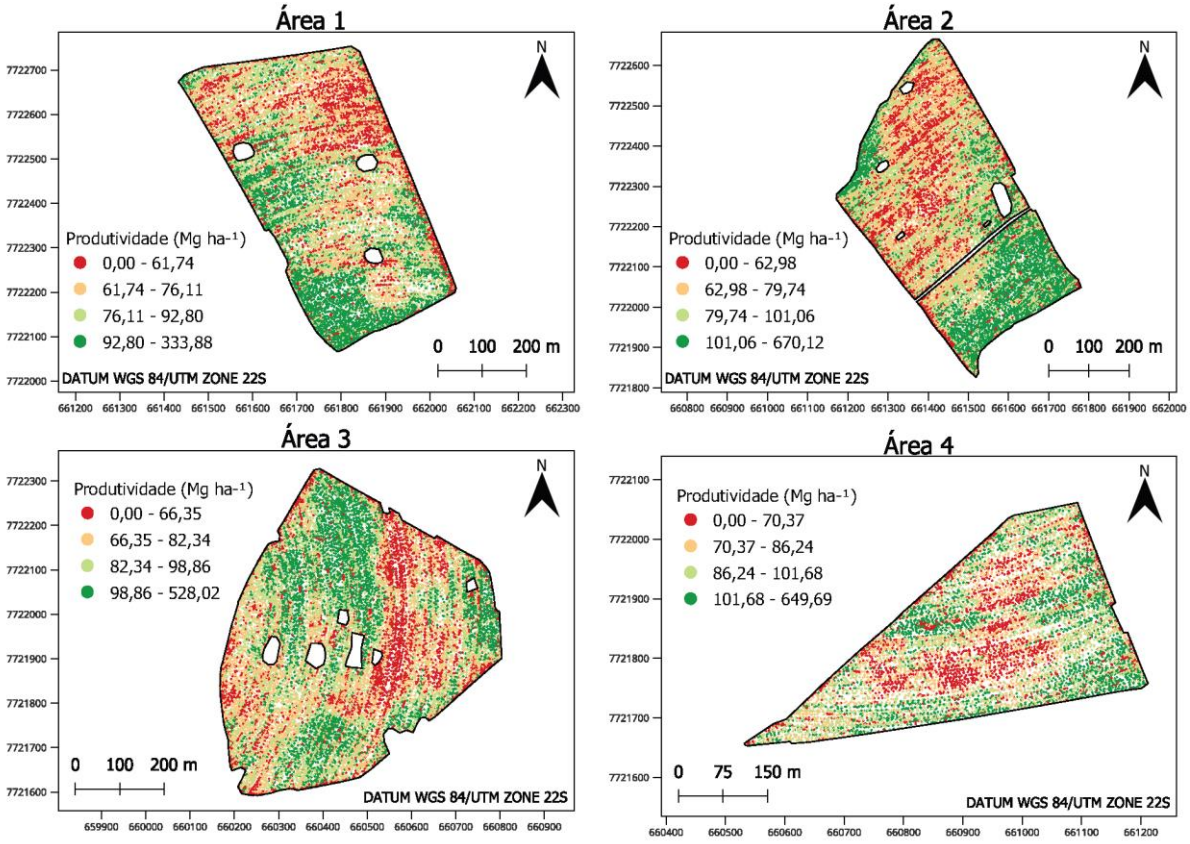


FIGURA 1. Mapas de pontos da produtividade de cana-de-açúcar em todas as áreas com seus respectivos dados brutos, sem a adição de dados discrepantes artificiais.

FIGURA 1. Mapas de pontos da produtividade de cana-de-açúcar em todas as áreas com seus respectivos dados brutos, sem a adição de dados discrepantes artificiais.

A Figura 2 mostra a espacialidade dos dados sem os dados discrepantes artificiais de cada área após serem filtrados pelos cinco métodos e nela é possível visualizar espacialmente como o método 2 se diferenciou dos outros. Observando a Figura 2 e a Tabela 1, pode-se afirmar que o método 2 foi o que mais filtrou os dados, utilizando limites superiores menores e inferiores maiores em todas as áreas analisadas. Como resultado, tem-se os maiores valores de mínimo e menores para os de máximo, desvio padrão e coeficientes de variação. Porém, observando a baixa amplitude de dados resultantes, há a possibilidade de que nem todos os dados filtrados eram discrepantes.

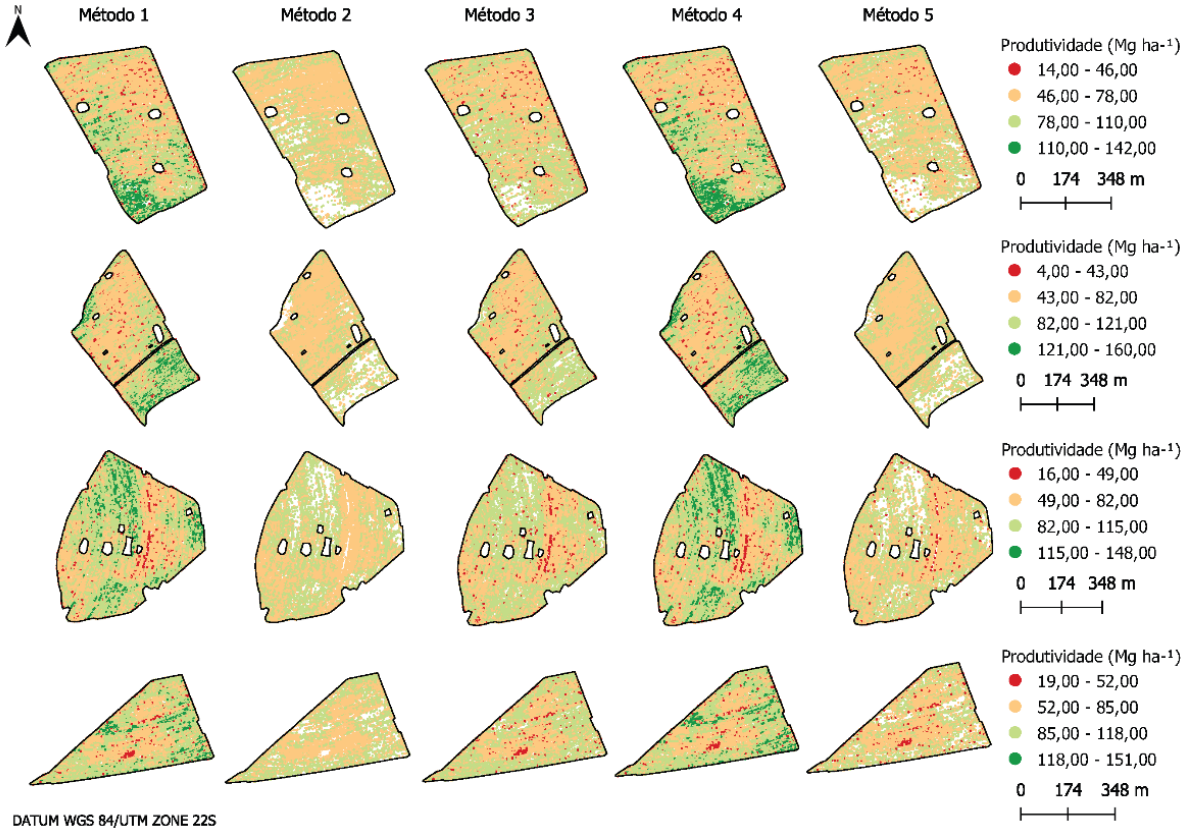


FIGURA 2. Mapas de pontos da produtividade de cana-de-açúcar em todas as áreas com seus respectivos dados filtrados pelos respectivos métodos, sem a adição de dados discrepantes artificiais.

O desempenho de cada método de filtragem encontra é mostrado na Figura 3 e é baseado na porcentagem de dados discrepantes artificiais que cada método foi capaz de identificar e remover. Pode-se afirmar que um comportamento em comum entre todos os métodos de filtragem foi de que quanto maior o valor de OM (magnitude de dado discrepante), maior a porcentagem de detecção alcançada pelos métodos e, consequentemente, maior seu desempenho.

Em média, os métodos 1 e 4 foram os que atingiram as menores porcentagens de desempenho, sendo na maioria das vezes incapazes de atingir um desempenho superior a 90% mesmo com o valor de ± 1,00 de OM. Estes dois métodos foram apenas capazes de atingir um desempenho de detecção acima de 20,00% nas áreas 1, 2 e 3 quando o valor de OM era igual ou superior a ± 0,50. O método 4 quase sempre apresentou um desempenho inferior ao do método 1, sendo igual somente duas vezes e nunca maior.

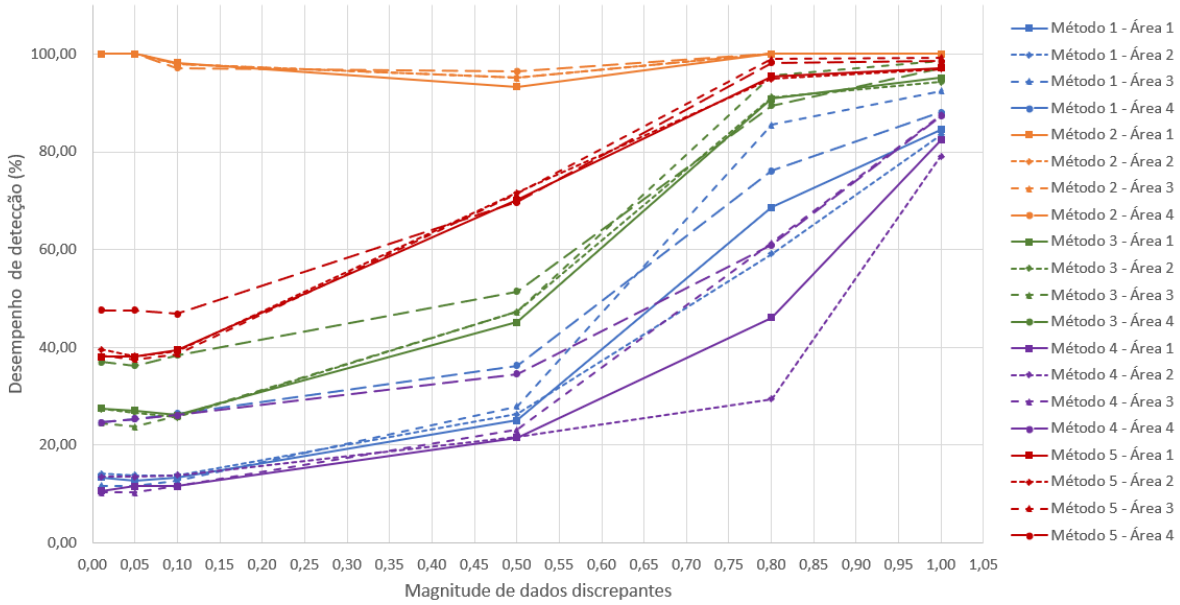


FIGURA 3. Desempenho de detecção de dados discrepantes artificiais (%) pelos métodos de filtragem propostos.

Sendo assim, os métodos 1 e 4 foram os de menor desempenho de detecção de dados discrepantes artificiais neste estudo, isso é esperado pois ambos os métodos são eficazes apenas para dados simetricamente distribuídos em torno de uma média constante (CASTELEYN et al., 2023; DASH et al., 2023).

Os métodos 2, 3 e 5 foram os de maior desempenho neste estudo. O método 3 apresentou um desempenho acima de 90,00% apenas para valores de magnitude de dados discrepantes acima de ± 0,80, sendo incapaz de apresentar um desempenho acima de 38,00% em todas as áreas para valores de ± 0,01 OM, ultrapassando esse valor apenas para OM acima de ± 0,10. O método 5, por outro lado, alcançou e ultrapassou essa porcentagem de desempenho para os valores de menor magnitude de dados discrepantes (± 0,01 de OM), porém apresentou um desempenho acima de 90% apenas nos maiores valores de magnitude de dados discrepantes.

O método 2 atingiu os maiores desempenhos de detecção de dados discrepantes neste estudo, sendo sempre capaz de atingir 100% de desempenho para valores de magnitude (OM) de ± 0,01, ± 0,05, ± 0,80 e ± 1,00. Em nenhum momento este método apresentou uma porcentagem de desempenho acima de 99,00% para valores de ± 0,10 e ± 0,50 de OM, porém sempre se manteve entre 93,00 e 98,00%.

Essa discrepância de desempenho entre o método 2 e os outros métodos se deve ao fato de que o método 2 realiza análises locais, diferentes dos outros métodos baseados puramente em estatística. Logo, em estudos futuros é necessário compará-lo com métodos de filtragem baseados em distância, cluster, agrupamento e com janela móvel.

CONCLUSÃO

Todos os cinco métodos foram capazes de filtrar os dados de todas as áreas, apresentando diferentes porcentagens de remoção de dados. O método 1 e o método 4 foram o de menor desempenho na detecção de dados discrepantes artificias, enquanto o método 2, método 3 e método 5 foram o de maior desempenho nesta ordem.

A contaminação de conjunto de dados com dados artificias é uma abordagem promissora de identificação de dados discrepantes, entretanto ainda não é possível afirmar com convicção que

quanto maior o desempenho do método em filtrar estes dados, mais confiáveis são os dados resultantes da filtragem. Logo, são necessários mais estudos que comprovem se todos os dados filtrados por diversos métodos são de fato discrepantes com a realidade.

REFERÊNCIAS

BECK, H.; KÜHN, M. Dynamic Data Filtering of Long-Range Doppler LiDAR Wind Speed Measurements. **Remote Sensing 2017, Vol. 9, Page 561**, v. 9, n. 6, p. 561, 4 jun. 2017.

CASTELEYN, S.; OMETOV, A.; TORRES-SOSPEDRA, J.; SHEHU YARO, A.; MALY, F.; PRAZAK, P. Outlier Detection in Time-Series Receive Signal Strength Observation Using Z-Score Method with Sn Scale Estimator for Indoor Localization. **Applied Sciences 2023, Vol. 13, Page 3900**, v. 13, n. 6, p. 3900, 19 mar. 2023.

DASH, C. S. K.; BEHERA, A. K.; DEHURI, S.; GHOSH, A. An outliers detection and elimination framework in classification task of data mining. **Decision Analytics Journal**, v. 6, p. 100164, 1 mar. 2023.

HIGGINS, S.; SCHELLBERG, J.; BAILEY, J. S. Improving productivity and increasing the efficiency of soil nutrient management on grassland farms in the UK and Ireland using precision agriculture technology. **European Journal of Agronomy**, v. 106, p. 67-74, 1 maio 2019.

HODGE, V. J.; AUSTIN, J. A Survey of Outlier Detection Methodologies. **Artificial Intelligence Review 2004 22:2**, v. 22, n. 2, p. 85-126, out. 2004. Disponível em:

JEONG, J.; PARK, E.; HAN, W. S.; KIM, K.; CHOUNG, S.; CHUNG, I. M. Identifying outliers of non-Gaussian groundwater state data based on ensemble estimation for long-term trends. **Journal of Hydrology**, v. 548, p. 135-144, 1 maio 2017.

KLUYVER, T.; RAGAN-KELLEY, B.; PÉREZ, F.; GRANGER, B.; BUSSONNIER, M.; FREDERIC, J.; KELLEY, K.; HAMRICK, J.; GROUT, J.; CORLAY, S.; IVANOV, P.;

AVILA, D.; ABDALLA, S.; WILLING, C. Jupyter Notebooks - a publishing format for reproducible computational workflows. **Positioning and Power in Academic Publishing: Players, Agents and Agendas - Proceedings of the 20th International Conference on Electronic Publishing, ELPUB 2016**, p. 87-90, 2016.

LIN, L.; SHERMAN, P. D. Cleaning data the Chauvenet way. **Group - The Proceedings of the SouthEast SAS Users**, 2007.

LIU, J.; LIU, L.; DU, J.; SANG, J. TLE outlier detection based on expectation maximization algorithm. **Advances in Space Research**, v. 68, n. 7, p. 2695-2712, 1 out. 2021.

LUND, E.D.; MAXTON, C.R.; LUND, T. J. A Data Fusion Method for Yield and Soil Sensor Maps. **13th International Conference on Precision Agriculture**, St. Louis, Missouri, EUA, 2016.

LYLE, G.; BRYAN, B. A.; OSTENDORF, B. Post-processing methods to eliminate erroneous grain yield measurements: Review and directions for future development. **Precision Agriculture**, v. 15, n. 4, p. 377-402, 1 nov. 2014.

MALDANER, L. F.; MOLIN, J. P.; SPEKKEN, M. Methodology to filter out outliers in high spatial density data to improve maps reliability. **Scientia Agricola**, v. 79, n. 1, p. e20200178, 18 jan. 2021..

MALDANER, L. F.; CANATA, T. F.; MOLIN, J. P. An Approach to Sugarcane Yield Estimation Using Sensors in the Harvester and ZigBee Technology. **Sugar Tech**, v. 24, n. 3, p. 813-821, 1 jun. 2022.

MONTEIRO, A.; SANTOS, S.; GONÇALVES, P. Precision Agriculture for Crop and Livestock Farming-Brief Review. **Animals 2021**, Vol. 11, Page 2345, v. 11, n. 8, p. 2345, 9 ago. 2021.

R Core Team (2023). _R: A Language and Environment for Statistical Computing_. R Foundation for Statistical Computing, Vienna, Austria. <https://www.R-project.org/>.

SMITI, A. A critical overview of outlier detection methods. **Computer Science Review**, v. 38, p. 100306, 1 nov. 2020.

INTEGRANDO DADOS ESPACIAIS E MACHINE LEARNING PARA PREDIZER A MATURAÇÃO DE AMENDOIM

Octávio Pereira da Costa [1]; Thiago Orlando Costa Barboza [1]; Wender Henrique Batista da Silva [1]; Franklin Daniel Inácio [1]; Adão Felipe dos Santos [2]

[1]Bolsista . Universidade Federal de Lavras, Caixa Postal 3037, CEP 37200-900, Lavras/MG.. Universidade Federal de Lavras; [2]Docente . Universidade Federal de Lavras, Caixa Postal 3037, CEP 37200-900, Lavras/MG.. Universidade Federal de Lavras

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A estimativa do ponto de maturação das vagens de amendoim desempenha um papel crucial para a determinação do momento ideal da colheita mecanizada, influenciando diretamente na produtividade e perdas na colheita. A técnica Hull-scrape, comumente usada para avaliar esta maturação, baseia-se na raspagem das vagens e comparação da cor do mesocarpo com uma tabela padrão, que varia desde o branco, até o preto. Contudo, essa técnica apresenta desafios, sendo trabalhosa, subjetiva e não considerando a variabilidade espacial da maturação no campo. Recentemente, a agricultura de precisão e digital emergiram como ferramentas potenciais para mapear tal variabilidade. O presente trabalho visa desenvolver modelos de predição da maturação das vagens integrando índices de vegetação e dados climáticos, através de técnicas de machine learning. Para esta finalidade, foram coletadas amostras georreferenciadas de campos comerciais de amendoim em diferentes localidades e classificadas utilizando a metodologia Hull-scrape. Adicionalmente, imagens de satélite e dados de estações meteorológicas com modelos de circulação global (NASA-Power) foram empregados. Com este estudo, almeja-se predizer de forma remota e não-destrutiva a maturação do amendoim, levando em conta a variabilidade espacial e a fisiologia da planta, superando a subjetividade do método Hull-scrape. Os resultados revelam que o modelo Random Forest (RF) demonstra o melhor equilíbrio entre precisão e capacidade de explicar a variabilidade dos dados, apresentando as métricas mais favoráveis. No entanto, outros modelos, como Support Vector Machine (SVM), também exibem desempenhos notáveis, oferecendo diferentes perspectivas e escolhas dependendo das prioridades específicas do usuário.

PALAVRAS-CHAVE: Inteligência artificial; Modelagem; Sensoriamento remoto

ABSTRACT

A estimation of peanut pod maturity plays a crucial role in determining the optimal time for mechanized harvesting, directly influencing productivity and harvest losses. The Hull-scrape technique, commonly used to assess this maturity, relies on scraping the pods and comparing the color of the mesocarp to a standard chart, ranging from white to black. However, this technique poses challenges, being labor-intensive, subjective, and not accounting for spatial variability in maturity in the field. Recently, precision and digital agriculture have emerged as potential tools to map such variability. This study aims to develop prediction models for pod maturity by integrating vegetation indices and climate data through machine learning techniques .For this purpose, georeferenced samples were collected from commercial peanut fields in different locations and classified using the Hull-scrape methodology. Additionally, satellite images and data from meteorological stations with global circulation models (NASA-Power) were employed. With this study, the goal is to predict peanut maturity remotely and non-destructively, taking into account spatial variability and plant physiology, overcoming the subjectivity of the Hull-scrape method. The results reveal that the Random Forest (RF) model demonstrates the best balance between accuracy and ability to explain data variability, presenting the most favorable metrics. However, other models, such as Support

Vector Machine (SVM), also exhibit notable performances, offering different perspectives and choices depending on the specific priorities of the user.

KEYWORDS: ;;

INTRODUÇÃO

A cultura do amendoim é amplamente difundida nas Américas, sendo nesse continente o maior produtor e consumidor os Estados Unidos e na América do Sul os maiores produtores são Brasil e Argentina (USDA, 2023). Independentemente do local, as plantas de amendoim apresentam os mesmos problemas relacionado a variabilidade na maturação das vagens.

A maturação das vagens de amendoim é um processo desuniforme, uma vez que as plantas iniciam o florescimento após 30 dias da semeadura (Boote, 1982), desde então, dependendo de variáveis climáticas e condições propicias ao desenvolvimento as vagens começam o processo de maturação. Assim como em outras culturas, a maturidade fisiológica das vagens é que dita o início da colheita. É indicado que a operação de arranquio se inicie quando os valores do índice de maturação (PMI) da cultura estiverem próximos 0,70 a 0,75 (Santos *et al*., 2021, Souza *et al*., 2022). No entanto, por se tratar de uma planta de hábito de crescimento indeterminado a variabilidade inter e intraplanta da maturação é alta, fato esse que não é contabilizado durante o processo de avaliação da maturação por métodos tradicionais (Santos *et al*., 2021).

O método tradicional de avaliação, baseado no quadro de maturação de William e Drexler (1981), apresenta alta subjetividade, não levando em conta a variabilidade intra e interplanta (Santos *et al*., 2022). Além disso, o hábito de crescimento indeterminado do amendoim resulta na produção de flores ao longo de 30 dias após a semeadura até o arranquio (Boote, 1982), enquanto a temperatura pode modular o ciclo da cultura, afetando a maturação das vagens.

Assim, o uso de imagens de satélites e drones já foram reportados com sucesso para predizer a maturação de amendoim tanto no Brasil quanto nos EUA (Souza *et al*., 2022, Santos *et al*., 2022). Vale ressaltar que a maioria do cultivo de amendoim no Brasil entra como opção de sucessão com a cana-de-açúcar e nessas situações o monitoramento da maturação via imagens de satélite pode ser uma alternativa para manejo dos talhões, que comumente são arrendados e estão distantes uns dos outros (Santos *et al*., 2021).

Entretanto, as ferramentas utilizadas nos trabalhos encontrados na literatura utilizaram em sua maioria Redes Neurais Artificiais, as quais possuem boa capacidade em resolver problemas complexos e não lineares. Contudo, é essencial verificar outros algoritmos mais simples e que requer menos recursos computacionais para ajudar na digitalização da cultura do amendoim. Além disso, é importante associar valores de índices de vegetação com informações climáticas as quais apresentam boa relação com a maturação de amendoim (Barboza *et al*., 2024).

OBJETIVOS

Objetiva-se verificar a eficiência de algoritmos de aprendizado de máquina (Random Forest RF e o Support Vector Machine SVM), para reconhecimento de padrões e generalização do estado de maturação da cultura do amendoin utilizando índices de vegetação e dados climáticos.

MATERIAL E MÉTODOS

O experimento foi conduzido em um campo comercial cultivado com a cultivar IAC OL3 com ciclo variando de 125 a 130 dias semeado em espaçamento 0,90 m em sistema MEIOSI com cana-de-

açúcar. O campo é localizado no município de Iturama, Minas Gerais, com plantio em 23 de outubro de 2021 (Figura 1).

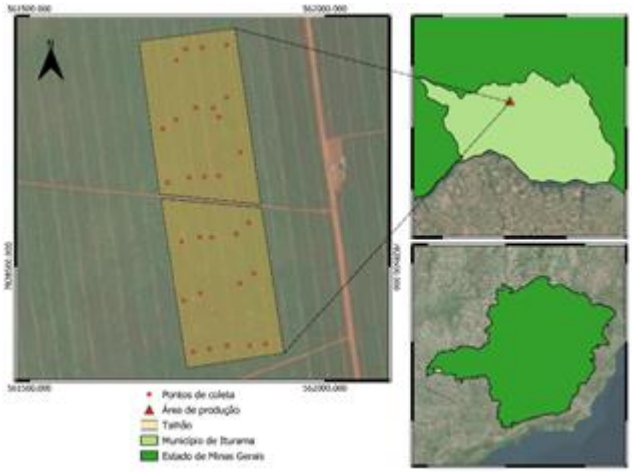


FIGURA 1. Mapa de Localização da área de estudo, no município de Iturama - MG.

As amostras de plantas de amendoim foram coletadas em campo e com o auxílio de um receptor navegação global por satélite (GNSS) foram georreferenciados para posterior aquisição dos dados de sensoriamento remoto. Inicialmente foi realizada a avaliação pela técnica de método hull-scrap com o quadro de maturação de William e Drexler (1981). Os dados provenientes do sensoriamento remoto deste estudo foram obtidos da Plataforma NASA POWER, sendo utilizados a radiação global (Qg), temperatura máxima (tmax), mínima (tmin) e média (tmean) e da constelação de satélites Planet Scope foi realizada a aquisição das imagens e cálculo dos índices de vegetação:

TABELA 1. Tabela de índices de vegetação.

Índices de vegetação	Equação	Referência
NDVI[1]	$\frac{(NIR - R)}{(NIR + R)}$	Rousé *et al*. (1973)
GNDVI[2]	$\frac{(NIR - G}{(NIR + G)}$	Gitelson; Kaufman; Merzlyak (1996)
SAVI[3]	$\frac{1{,}5 \times (NIR - R)}{(NIR + R + 0{,}5)}$	Huete (1988)
OSAVI[4]	$\frac{1{,}16 \times (NIR - R)}{(NIR + R + 0{,}16)}$	Rondeaux; Steven; Baret (1996)
MNLI[5]	$\frac{(NIR^2 - R) * (1{,}5)}{(NIR^2 + R + 0{,}5)}$	Gong *et al*. (2003)
NLI[6]	$\frac{(NIR^2 - R)}{(NIR^2 - R)}$	Goel; Qin (1994)
RVI[7]	$\frac{NIR}{R}$	Major; Baret; Guyot (1990)
RDVI[8]	$\frac{(NIR - R)}{(NIR + R)^{0{,}5}}$	Louis-Roujean; Breon (1995)
EVI[9]	$\frac{2{,}5 \times (NIR - R)}{(NIR + 6 \times R - 7{,}5 \times B + 1)}$	Huete *et al*. (1997)

Após a obtenção dos dados, foi realizado o pré-processamento, incluindo a transformação e remoção de variáveis que não seriam utilizadas, análise exploratória, pra melhor visualização da distribuição

das variáveis, médias de tendência central. Por fim, realizou-se a análise de correlação de Spearman ($p > 0.005$) e do valor do fator de inflação da variância (VIF), para a avaliação da multicolinearidade das variáveis preditoras do modelo.

Os dados foram divididos em três conjuntos de acordo com o método k-folds, que consiste em dividir o conjunto de dados em k partes iguais, onde k é o número de partições desejadas. O modelo é treinado k vezes, utilizando k-1 partes para treinamento e 1 parte para teste em cada iteração. Essa abordagem ajuda a mitigar o problema da variabilidade na seleção aleatória dos dados. Foram treinados modelos de Máquinas de Vetores de Suporte (SVM) utilizando kernel linear e radial, além de Random Forest (RF). Durante o treinamento, diversos hiperparâmetros foram ajustados para otimização do desempenho dos modelos.

A tabulação, análise exploratória, treinamento e avaliação dos modelos foi realizada utilizando o Software R® versão 4.3.2 (R Core Team, 2023), com o auxílio das bibliotecas "dplyr" (Wickham *et al*., 2023), "caret" (Kuhn, 2008) e "randomforrest" (Liaw; Wiener, 2002).

A avaliação dos modelos foi conduzida utilizando métricas como Erro Absoluto Médio (MAE), Erro Quadrático Médio (MSE), Raiz do Erro Quadrático Médio (RMSE) e o coeficiente de determinação (R^2).

Adicionalmente, a análise de resíduos foi realizada para cada modelo, visando examinar a diferença entre os valores previstos e reais. Essa análise é importante para a inferência sobre a qualidade e a adequação dos modelos aos dados.

RESULTADOS E DISCUSSÃO

As variáveis que apresentaram maior correlação com o PMI foram as variáveis climáticas, com correlação positiva maior que 0,7 (Figura 2). Esses resultados ressaltam a importância de associar variáveis climáticas nas estimativas de maturação das plantas de amendoim, especialmente associado com dados espectrais, que ajudam a entender a variabilidade espacial das plantas.

Vale ressaltar que o acúmulo de graus dias é importante para a maturação porque influencia diretamente o tempo que a cultura leva para atingir determinados estágios, como a formação e o desenvolvimento das vagens. Temperaturas mais altas podem acelerar o desenvolvimento, enquanto temperaturas mais baixas podem retardá-lo e é amplamente utilizado por produtores nos EUA (Rowland *et al*., 2006).

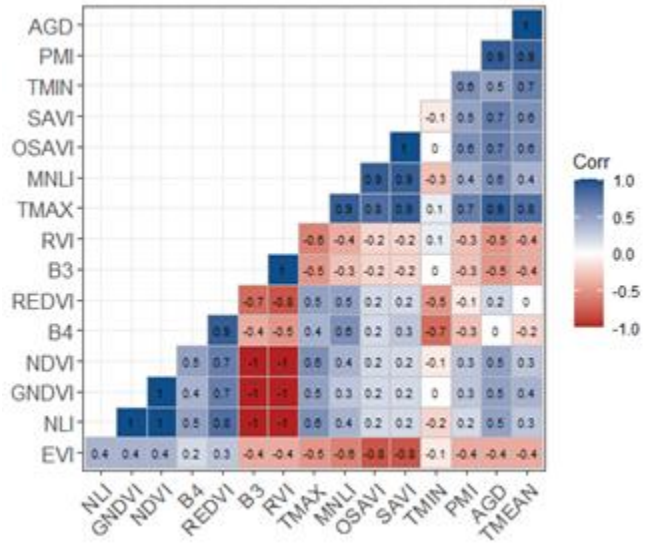


FIGURA 2. Matriz de correlação entre as variáveis do banco de dados.

Os índices NDVI, NLI e OSAVI foram os que apresentaram maior correlação (Figura 2). Os índices de vegetação também são variáveis importantes para a estimativa do PMI, especialmente porque eles são capazes de captar a variabilidade temporal e espacial, principalmente quando estes apresentam correlação negativa maior que 0,7, o que significa que plantas com maturação mais avançada tendem a ter menores valores de índices de vegetação (Santos *et al*., 2021; Santos *et al*., 2022).

Os modelos de aprendizado de máquina, RF e SVM apresentaram bons valores de coeficiente de correlação, acima de 0,7 (Tabela 2). Isso demonstra que estes modelos têm uma boa capacidade de generalização, e conseguem trabalhar associando uma grande quantidade de variáveis preditoras. De modo similar, porém com uma maior demanda de recursos computacionais as RNA's apresentam ser uma alternativa viável para a estimativa do PMI na cultura do amendoim, seja utilizando imagens de Aeronaves remotamente pilotadas (ARP) em condições irrigadas ou não irrigadas (Santos *et al*., 2022), ou utilizando imagens de alta resolução de satélite (Souza *et al*., 2022).

Os métodos ensemble, como o RF e SVM, são alternativas para a avaliação não destrutiva da maturação de vagens, pois apesar de apresentarem um ajuste inferior dos modelos, a capacidade computacional exigida para o processamento dos dados é reduzida, facilitando a obtenção dos modelos. A otimização do processamento é favorecida pelo método de treinamento, onde várias árvores de decisão são treinadas de forma independente (Nitze; Schulthess; Asche, 2012).

TABELA 2. Resultados dos algoritmos utilizados para estimativa da maturação de amendoim utilizando como entrada índices de vegetação (IV) e dados climáticos.

Modelo	MAE	MSE	RMSE	R^2
SVM - Linear	0.084	0.019	0.138	0.805
SVM - Radial	0.092	0.019	0.138	0.797
Randon Forrest	0.085	0.019	0.140	0.800

CONCLUSÃO

A utilização de modelos de aprendizado de máquina, Random Forrest e Suport Vector Machines, são uma alternativa viável para a estimativa do PMI da cultura do amendoim, necessitando de menos capacidade computacional e modelos mais simples, porém, da mesma forma reduzindo a subjetividade dos métodos tradicionais de determinação.

AGRADECIMENTOS

Agradecemos à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio e financiamento deste trabalho.

REFERÊNCIAS

BARBOZA, T. O. C. *et al*. Advanced Farming Strategies Using NASA POWER Data in Peanut-Producing Regions without Surface Meteorological Stations. **AgriEngineering**, v. 6, n. 1, p. 438-454, 2024.

BOOTE, K. J. Growth stages of peanut (*Arachis hypogaea* L.). **Peanut science**, v. 9, n. 1, p. 35-40, 1982.

GITELSON, Anatoly A.; KAUFMAN, Yoram J.; MERZLYAK, Mark N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote sensing of Environment**, v. 58, n. 3, p. 289-298, 1996.

GOEL, N. S.; QIN, W. Influences of canopy architecture on relationships between various vegetation indices and LAI and FPAR: A computer simulation. **Remote Sensing Reviews**, v. 10, n. 4, p. 309-347, 1994.

GONG, Peng *et al*. Estimation of forest leaf area index using vegetation indices derived from Hyperion hyperspectral data. **IEEE transactions on geoscience and remote sensing**, v. 41, n. 6, p. 1355-1362, 2003.

HUETE, A. R. *et al*. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote sensing of environment**, v. 59, n. 3, p. 440-451, 1997.

HUETE, Alfredo R. A soil-adjusted vegetation index (SAVI). **Remote sensing of environment**, v. 25, n. 3, p. 295-309, 1988.

KUHN, Max. Building predictive models in R using the caret package. **Journal of statistical software**, v. 28, p. 1-26, 2008.

LIAW, A.; WIENER, M. Classification and regression by randomForest. **R news**, v. 2, n. 3, p. 18-22, 2002.

MAJOR, D. J.; BARET, F. E. D. E.; GUYOT, G. A ratio vegetation index adjusted for soil brightness. **International journal of remote sensing**, v. 11, n. 5, p. 727-740, 1990.

NITZE, I.; SCHULTHESS, U.; ASCHE, H. Comparison of machine learning algorithms random forest, artificial neural network and support vector machine to maximum likelihood for supervised crop type classification. **Proceedings of the 4th GEOBIA, Rio de Janeiro, Brazil**, v. 79, p. 3540, 2012.

R Core Team. R: A Language and Environment for Statistical Computing. **R Foundation for Statistical Computing**, Vienna, Austria, 2023. Disponível em: <https://www.R-project.org/>.

RONDEAUX, Geneviève; STEVEN, Michael; BARET, Frédéric. Optimization of soil-adjusted vegetation indices. **Remote sensing of environment**, v. 55, n. 2, p. 95-107, 1996.

ROUJEAN, Jean-Louis; BREON, François-Marie. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. **Remote sensing of Environment**, v. 51, n. 3, p. 375-384, 1995.

Rousé, J. W. *et al*. Monitoring vegetation systems in the great plains with ERTS. *In*: Third ERTS Symposium, **Proceedings**, NASA SP-351, NASA, Washignton, DC, v. 1, p. 309-317, 1973.

ROWLAND, D. L. *et al*. Determination of maturity and degree day indices and their success in predicting peanut maturity. **Peanut Science**, v. 33, n. 2, p. 125-136, 2006.

SANTOS, A.F. et al. High-resolution satellite image to predict peanut maturity variability in commercial fields. **Precision Agric,** v. 22, p. 1464-1478, 2021.

SOUZA, J. B. C. *et al*. Integrating Satellite and UAV Data to Predict Peanut Maturity upon Artificial Neural Networks. **Agronomy**, v. 12, n. 7, p. 1512, 2022.

USDA. Peanut. United States Departament of Agriculture. **Peanut Explores**, 2023. Disponível em: < https://ipad.fas.usda.gov/cropexplorer/cropview/commodityView.aspx?cropid=2221000 >. Acesso em: 12 dez. 2023.

WICKHAM, H. *et al*. Dplyr: A Grammar of Data Manipulation. **R package**, version 1.1.3, 2023. Disponível em: <https://CRAN.R-project.org/package=dplyr>.

METODOLOGIA RELM-BLUP APLICADA A SELEÇÃO DE ATRIBUTOS ESPECTRAIS E PREDIÇÃO DE VARIÁVEIS NA CULTURA DO MILHO

Charleston dos Santos Lima [1]; Luiza Rathke [2]; Ivan Ricardo Carvalho [3]; Christian Bredemeier [4]
[1]Bolsista. Faculdade de, Campus do Vale - Av. Bento Gonçalves, 7712 - Agronomia, Porto Alegre - RS, 91540-000. Universidade Federal do Rio Grande do Sul; [2]Bolsista. Avenida Bento Gonçalves, 7712 - Agronomia, Porto Alegre - RS, 91540-000. Universidade Federal do Rio Grande do Sul; [3]Docente. Rua do Comércio, 3000, Bairro Universitário, Ijuí -RS, 98700000. Universidade Regional do Noroeste do Estado do Rio Grande do Sul; [4]Docente. Avenida Bento Gonçalves, 7712 - Agronomia, Porto Alegre - RS, 91540-000. Universidade Federal do Rio Grande do Sul

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
Índices de vegetação e atributos de textura de imagens podem ser afetados por fatores ambientais como variação do estádio fenológico, o que pode modificar a performance dos parâmetros ao longo do ciclo. Neste sentido, o objetivo do presente estudo foi avaliar a aplicação da metodologia de modelos mistos (RELM-BLUP) na seleção de atributos de imagens e predição de variáveis fitomorfológicas na cultura do milho. 6 doses de nitrogênio foram aplicadas em delineamento de blocos casualizados com 4 repetições, sendo realizada a coleta de imagens em 5 estádios (v8, v11, v18, R2 e R5). Todas as variáveis foram utilizadas na análise de máxima verossimilhança e melhor preditor não viesado (RELM-BLUP), e posteriormente realizada a predição de biomassa, altura de plantas e nitrogênio no tecido. Os resultados mostraram que índices de vegetação com herdabilidade >60% e menor influência do erro experimental apresentaram adequada estratificação dos cenários (Doses) em cada voo. Conforme observado para o índice RBI, o que não foi observado para o índice NDB. Adicionalmente, verificou-se coeficiente de determinação > 0,80 para todas as variáveis preditas a partir da utilização da metodologia. Conclui-se que, a metodologia RELM-BLUP pode ser aplicada para a seleção de melhores parâmetros, com redução da influência do estádio fenológico e incremento da acurácia nas predições.

PALAVRAS-CHAVE: Sensoriamento remoto; Fenologia; Ambiente

ABSTRACT
Vegetation indices and texture attributes of images can be affected by environmental factors such as variation in phenological stage, which can modify the performance of parameters during growth of maize. In this sense, the main of study was to evaluate the application of methodology of likelihood maximum model (REML-BLUP), in selection of images attributes and prediction of variables in maize culture. six nitrogen doses were applied in casualized blocks with four repetition, and realized the aquisition of images in 5 stages (v8, v11, v18, R2 e R5). Every variables were utilized in analysis of likelihood maximum test and best linear unbiased prediction (RELM-BLUP), and after was realized the prediction of biomass, height of plants and tissue nitrogen. The results showed that vegetation indices with high heritability >60% and low experimental error were suitable for stratifying scenarios (doses) in each flight. As observed for the RBI index, which was not observed for the NDB index. Additionally, a coefficient of determination >0.80 was found for all predicted variables using the methodology. It is concluded that the RELM-BLUP methodology can be applied to select better parameters, reducing the influence of the phenological stage and increasing accuracy in predictions.

KEYWORDS: ;

INTRODUÇÃO

A predição de caracteres agronômicos com base em informações obtidas com veículos aéreos não tripulados (VANT's), tem aumentado significativamente nos últimos anos (CHIVASA et al., 2021; YANG et al., 2022). Devido à alta resolução espacial e temporal que tais plataformas podem oferecer, o que permite o imageamento das culturas em diferentes estádios fenológicos e avaliação da resposta espectral sob diferentes cenários de cultivos ou estresses abióticos (ABRAHAMS et al., 2023).

Dentre os principais atributos espectrais obtidos com o uso de VANT's, destacam-se os índices de vegetação baseados em regiões do espectro visível e infravermelho. Neste sentido, Ma et al. (2023), constataram que o índice por diferença normalizada (NDVI) e índice por diferença normalizada do verde (GNDVI), apresentaram melhor correlação com a área foliar, conteúdo de clorofilas e altura de plantas na cultura do milho. Adicionalmente, Sun et al. (2023) observaram que o NDVI e atributos de textura entropia e média de bandas, apresentaram correlação significativa com a área foliar da cultura e melhor acurácia de predição ($r^2 > 80\%$).

Embora tais características sejam relevantes para o monitoramento de plantas, alguns problemas intrínsecos de cada atributo geram alta inconsistência nos resultados, devido a fatores ambientais como variação do estádio fenológico ou efeito de ano (SHRESTHA et al., 2023), com alteração do melhor parâmetro para a predição de variáveis dependendo do cenário. Além disso, observa-se alta influência da temperatura, luminosidade, incremento de biomassa e discrepância de tratamentos, o que tende a reduzir o coeficiente de determinação das predições abaixo de 70% (CHEN et al., 2018).

Considerando os fatores que podem afetar a predição de variáveis na cultura do milho, a resposta das plantas a doses de nitrogênio (N) torna-se imprescindível, ocorrendo variabilidade espacial e temporal em decorrência da diferença nutricional entre plantas e estádio fenológico amostrado. O que demanda a aplicação de metodologias estatísticas que permitam a dedução do efeito ambiental presente nos dados e melhorar a predição de caracteres de importância agronômica (CARVALHO et al., 2018).

OBJETIVOS

O objetivo do presente estudo foi avaliar a aplicação da metodologia de modelos mistos (RELM-BLUP) na seleção de atributos de imagens e predição de variáveis fitomorfológicas de plantas de milho submetidas a diferentes doses de N.

MATERIAL E MÉTODOS

O experimento foi conduzido junto a Estação Experimental Agronômica da Universidade Federal do Rio Grande do Sul (EEA-UFRGS), situada no município de Eldorado do Sul/RS (434388,2 Sul, 6668671 Oeste) (Figura 1). A área experimental foi cultivada com aveia branca para cobertura do solo durante o inverno, sendo realizado a dessecação das plantas quando as mesmas estavam no estádio fenológico de florescimento.

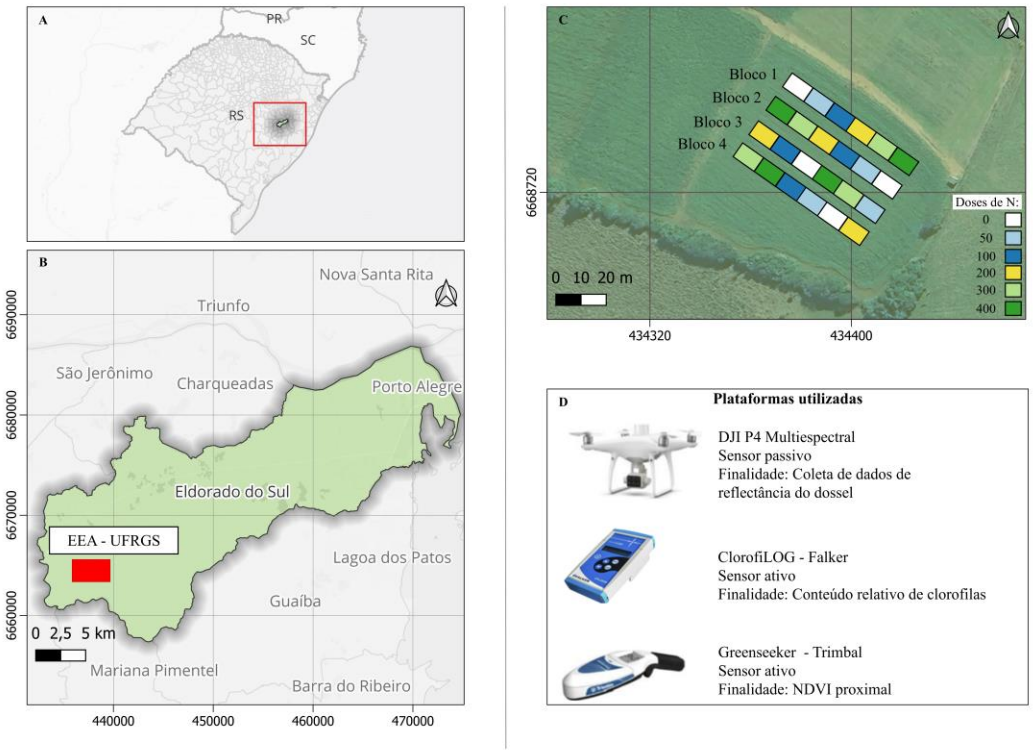


FIGURA 1. Localização da área experimental (A e B), desenho experimental (C) e plataformas de sensoriamento remoto utilizadas (D).

A semeadura da cultura do milho foi realizada no dia 27 de outubro de 2022, sendo utilizado o híbrido P3016 VYHR, em sistema plantio direto com densidade de 8 plantas m², as quais já apresentavam tratamento de sementes industrial. A adubação de base foi constituída de 20 kg ha^{-1} N, 120 kg ha^{-1} P_2O_5 e 60 kg ha^{-1} K_2O. As unidades experimentais foram constituídas de 5 linhas de cultivo espaçadas a 0,5 metros e com 5 metros de comprimento, totalizando 12,5 m². Demais tratos culturais foram feitos de acordo com as recomendações técnicas da cultura do milho.

Para garantir maior variabilidade na coleta de imagens, foram aplicadas 6 doses de N em cobertura (0, 50, 100, 200, 300 e 400 kg ha^{-1}), com aplicação total realizada no estádio fenológico de 5 folhas (v5), em delineamento de blocos casualizados com 4 repetições (Figura 1C).

Após a aplicação dos tratamentos, nos estádios fenológicos v8, v11, v18, R2 e R5, determinou-se a altura em 10 plantas de cada parcela, a partir de medição direta da planta com régua graduada da superfície do solo até a base do pendão, com os valores expressos em metros $planta^{-1}$. Concomitantemente, realizou-se o corte de 3 plantas de cada parcela, as quais foram secas em estufa de ar forçado a 60 ºC para posterior determinação da biomassa de planta. Com os valores expressos em quilograma de matéria seca por hectare. Após a pesagem das plantas, realizou-se a moagem do material em moinho tipo willey e determinação do percentual de nitrogênio no tecido (N_planta), com destilador do tipo Kjeldahl e titulação com H_2SO_4.

O conteúdo de clorofilas totais (CHLT) em cada estádio fenológico foi estimado via método SPAD com auxílio do clorofilog (Figura 1D), sendo as medições efetuadas em 10 plantas por parcela na última folha completamente expandida (v8, v11 e V18) e na folha da espiga (R2 e R5) (ARGENTA; SANGOI, 2004). Também foi realizada a leitura de NDVI proximal com espectroradiômetro equipado com um sensor ativo (Greenseeker, Trimble) (Figura 1D), o qual emite radiação em comprimento de onda no vermelho (660 nm) e infravermelho próximo (790 nm). Tal procedimento é utilizado como parâmetro de referência para dados de NDVI coletados em diferentes cultivos.

A coleta de imagens para avaliação espectral das parcelas submetidas aos diferentes tratamentos de N foi realizada nos estádios v8, v11, v18, R2 e R5. Com a coleta de dados biométricos realizada no mesmo dia, para evitar mudanças nas condições ambientais entre a avaliação real e captura de imagens.

Todos os voos para a coleta de imagens foram realizados com auxílio de um veículo aéreo não tripulado de asa rotativa DJI Phantom 4 RTK multiespectral (Figura 1D), com controle de voo autônomo via aplicativo Pix4D. O qual permitiu a obtenção da reflectância multiespectral das plantas nos comprimentos de onda do vermelho (R: 660 nm), verde (G: 550 nm), azul (B: 450 nm), Red-Edge (RE: 730 nm) e infravermelho próximo (NIR: 840 nm), com resolução de 2,08 megapixels por canal. As configurações gerais consistiram de sobreposição frontal e lateral de 75%, altura de voo de 30 metros, ângulo da câmera de 90º e sentido do voo diagonal as parcelas.

O horário para a coleta de imagens foi o mesmo para todos os voos, os quais foram executados entre 11:00 a 14:00h. Adicionalmente, utilizou-se o sensor de calibração (sunshine sensor) acoplado na extremidade superior do VANT para correção radiométrica das imagens.

O processamento de imagens foi realizado no software Agisoft Metashape para construção dos ortomosaicos, um para cada voo. Os quais foram associados a informações de sete pontos de controle de solo georreferenciados com GNSS-RTK para correção geométrica das fotos. Para a extração de informações espectrais dos ortomosaicos, utilizou-se o software Qgis e o plugin calculadora raster para a separação dos comprimentos de onda presentes em cada imagem. A partir disso, três linhas centrais em 4 metros de comprimento de cada parcela foram delimitadas pela adição de uma camada vetorial shapefile e então extraído o número digital nos comprimentos de onda no vermelho, verde, azul, red-edge e infravermelho. Posteriormente, realizou-se o cálculo de diferentes índices de vegetação na região do visível e multiespectral (Tabela 1). Adicionalmente, extraiu-se alguns atributos de textura das imagens com auxílio do plugin Orfeo no software Qgis, obtendo-se o valor médio dos parâmetros: Media, entropia, diferença de entropia e dissimilaridade, para cada shapefile das parcelas.

Para verificar o efeito de cenários (doses N), voos (estádios fenológicos) e a interação entre eles, aplicou-se o teste da máxima verossimilhança restrita (RELM), a fim de se obter a análise dos componentes da variância e valores estimados para cada variável pela análise da deviance ($p<0.05$). Conforme o modelo estatístico: $Yij = \mu + Bj + Gi + Ej + \varepsilon ij$. Onde: Yij é o valor mensurado para cada variável em cada parcela, Bj é o efeito de bloco (fixo), Gj indica o efeito atribuído as doses (fixo), Ej representa o efeito de ambiente: voos (aleatório) e εij o efeito associado ao erro experimental.

A partir da separação e quantificação dos efeitos associados, novos valores foram estimados pelo melhor preditor linear não viesado (BLUP). Obtendo-se, portanto, uma nova média para cada variável analisada, sem a interferência do ambiente (voo). Além disso, com intuito de verificar quais variáveis são mais importantes para a predição de biomassa, altura de planta e nitrogênio no tecido, aplicou-se um modelo de regressão por stepwise (backward), para remover variáveis colineares ou sem importância na predição. Posteriormente, foi realizado a plotagem dos modelos lineares com ou sem a metodologia RELM-BLUP. Toda a análise estatística foi realizada no software R studio utilizando os pacotes LM (linear model), Metan, e ggplot2.

TABELA 1. Índices de vegetação calculados a partir da reflectância de plantas de milho, safra 22/23.

Tipo	Índice	Equação	Referência
RGB	Excesso de verde	EXG= 2*G-R-B	Woebbecke et al. (1994)

	Excesso de vermelho	EXR= (1.4*R-G)/(R+G+B)	Meyer et al. (2008)
	Índice cor extração vegetação	CIVE= (0.44*R-0.81*G+0.39*B)/(R+G+B)+$^{18.79}$	Kataoka et al. (2003)
	Índice verde-vermelho normaliz.	GRVI= (G - R) / (G + R)	Meyer et al. (2008)
	Índice vegetativo	VEG= g/((r^a)*(b^(1-a)))	Hague et al. (2006)
	Diferença normalizada do azul	NDB= (G-B)/(G+B)	Meyer et al. (2008)
	Índice resistente à atmosfera visível	VARI= (G-R)/(G+R+B)	Gitelson et al. (2003)
	Índice de folha verde	GLI= ((G-R)+(G-B))/(2*G+R+B)	Louhaichi et al. (2001)
	Índice vermelho-Azul	RBI= (R-B)/(R+B)	Guo et al. (2020)
MULTIESPECTRAL	Diferença normalizada	NDVI= (NIR - R) / (NIR + R)	Tucker (1979)
	Borda do vermelho	NDRE= (NIR - RE) / (NIR + RE)	Rodriguez et al. (2006)
	Índice ajustado ao solo	SAVI= (1 + 0.5) * [(NIR - R)/(NIR + R + 0.5)]	Huete et al. (1992)
	Índice de vegetação melhorado	EVI= 2.5*(NIR-R)/(NIR+6*R -7.5*B+1)	Jiang et al. (2008)
	Diferença normalizado do verde	GNDVI= ((NIR-G)/(NIR+G))	Gitelson et al. (1996)
	Índice diferença da vegetação	DVI= NIR-R	Robertson et al (2012)
	Diferença normalizada do azul	BNDVI= (NIR-B)/(NIR+B)	Wang et al. (2007)
	PanNDVI	PanNDVI= NIR-(G+R+B)/ NIR+(G+R+B)	Wang et al. (2007)
	Profundidade de feição espectral	SFDVI= ((NIR+G)/2)-((R+NIR)/2)	Baptista (2015)

a=0.667, r=R/(R+G+B), g=G/(G+R+B), b=B/(R+G+B)

RESULTADOS E DISCUSSÃO

A partir da análise de máxima verossimilhança (Tabela 2), evidenciou-se efeito significativo para a interação cenários (doses N) x voos (estádios fenológicos), para a maioria dos parâmetros avaliados. Exceto para os índices NDB, NDVI, SAVI, EVI, DVI e atributo de textura média do vermelho (média_R). Adicionalmente, a análise dos componentes da variância para parâmetros contrastantes (Tabela 2), mostrou que variáveis como CHLT, EXR, NDVIG, GRVI, NDRE e RBI, embora apresentem efeito significativo para a interação cenários x voos (10% < r_2INT < 25%), mantém elevada herdabilidade (>60%), acurácia de resultados (>90%) e coeficiente de variação de cenários superior ao erro experimental (CVc/CVe >1.5). Similar ao comportamento observado para as variáveis de interesse agronômico: Biomassa, altura de plantas e nitrogênio no tecido (Tabela 2). Por outro lado, NDB, NDVI e SAVI apresentaram r_2INT < 10%, porém, demonstraram H^2 e relação CVc/CVe abaixo de 60% e 1,5, respectivamente. Com maior contribuição do erro experimental na magnitude dos resultados.

Componentes de variância são parâmetros importantes para a seleção de variáveis mais estáveis na avaliação de plantas, as quais apresentem menor influência da interação r_2INT, alta herdabilidade relação CVc/CVe. Neste sentido, Resende e Duarte (2007) postularam que parâmetros com valores de herdabilidade (>80%), acurácia (>70%) e relação CVc/CVe maior que 1, indicam confiabilidade nos dados e variação que pode ser atribuída aos efeitos fixos. Os quais referem-se aos cenários (doses

N) no presente estudo. O que permite a seleção de variáveis com menor influência dos fatores ambientais e maior contribuição do efeito de tratamento (FLINT-GARCIA et al., 2005; OLIVOTO et al., 2019). Garantindo adequada caracterização das diferentes doses de nitrogênio nos estádios fenológicos amostrados.

Tabela 2. Análise de máxima verossimilhança e componentes de variância.

Modelo	**NDVIG**	**CHLT**	**EXG**	**EXR**	**CIVE**	**GRVI**	**VEG**	**NDB**
Cenário	0.000*	0.000	0.001	0.000	0.000	0.000	0.000	0.005
Cen x voo	0.023	0.000	0.000	0.000	0.000	0.000	0.000	0.325
Modelo	**VARI**	**GLI**	**RBI**	**RGBindex**	**NDVI**	**SAVI**	**EVI**	**GNDVI**
Cenário	0.000	0.000	0.000	0.001	0.000	0.000	0.150	0.000
Cen x voo	0.001	0.000	0.000	0.000	0.254	0.255	0.005	0.000
Modelo	**NDRE**	**DVI**	**BNDVI**	**PanNDVI**	**SFDVI**	**Biomassa**	**ALT**	**Nplanta**
Cenário	0.000	0.000	0.014	0.002	0.000	0.003	0.000	0.000
Cen x voo	0.000	0.554	0.000	0.000	0.196	0.000	0.000	0.000

Componentes da variância

Parâmetro	**Biomassa**	**ALT**	**N**	**CHLT**	**NDVIG**	**GRVI**	**NDRE**	**RBI**	**NDB**	**NDVI**	**SAVI**
r_2INT	0.38	0.14	0.22	0.10	0.08	0.19	0.10	0.14	0.07	0.04	0.04
H^2	0.46	0.79	0.64	0.76	0.68	0.64	0.80	0.71	0.23	0.57	0.57
Acurácia	0.92	0.98	0.96	0.98	0.98	0.96	0.97	0.98	0.90	0.97	0.97
CVc/CVe	1.68	3.25	2.21	2.29	1.66	1.94	2.75	2.25	0.57	1.23	1.23

*Diferença significativa para valores de $p<0.05$. r_2INT: interação cenários x voos; H^2: Herdabilidade sentido amplo; CVc/CVe: relação coeficiente de variação de cenários/coeficiente variação do erro; N: nitrogênio no tecido; ALT: altura de plantas; CHLT: clorofilas totais.

Considerando os resultados dos componentes de variância, realizou-se a análise de BLUP para os índices contrastantes NDVIG (Greenseeker), NDRE, RBI, NDB, NDVI e SAVI (Figura 2, 3, 4, 5, 6 e 7). Foi evidenciado que os índices NDVIG, NDRE e RBI promoveram adequada estratificação dos cenários de acordo com os estádios fenológicos avaliados (Figura 2, 3 e 4). O que não foi observado para os índices NDB, NDVI e SAVI, uma vez que, embora os valores absolutos dos índices foram alterados com o crescimento da cultura, não foi observado diferença significativa entre as doses de N aplicadas na cultura do milho nos diferentes estádios fenológicos, exceto no florescimento (R5), quando as plantas deficientes de N já apresentavam elevada senescência. O que pode indicar uma menor sensibilidade de tais índices no início do desenvolvimento das plantas de milho e saturação precoce dos mesmos. Essa resposta também foi observada para os índices EVI, DVI e média_R (Dados não apresentados).

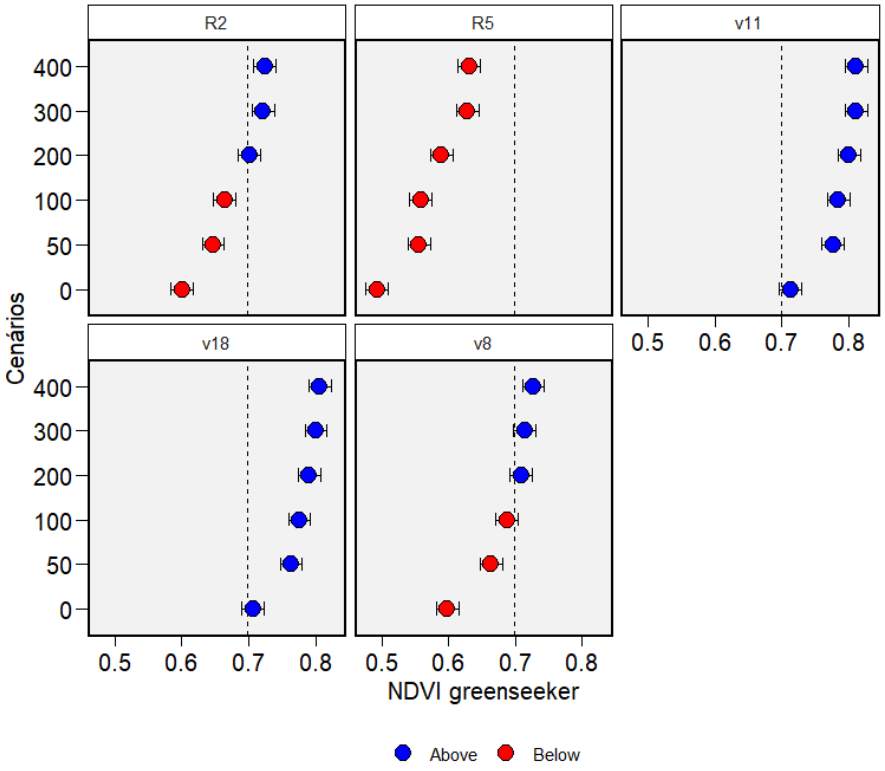


FIGURA 2. Análise de BLUP com os dados de cenários preditos para o índice NDVI - Greenseeker

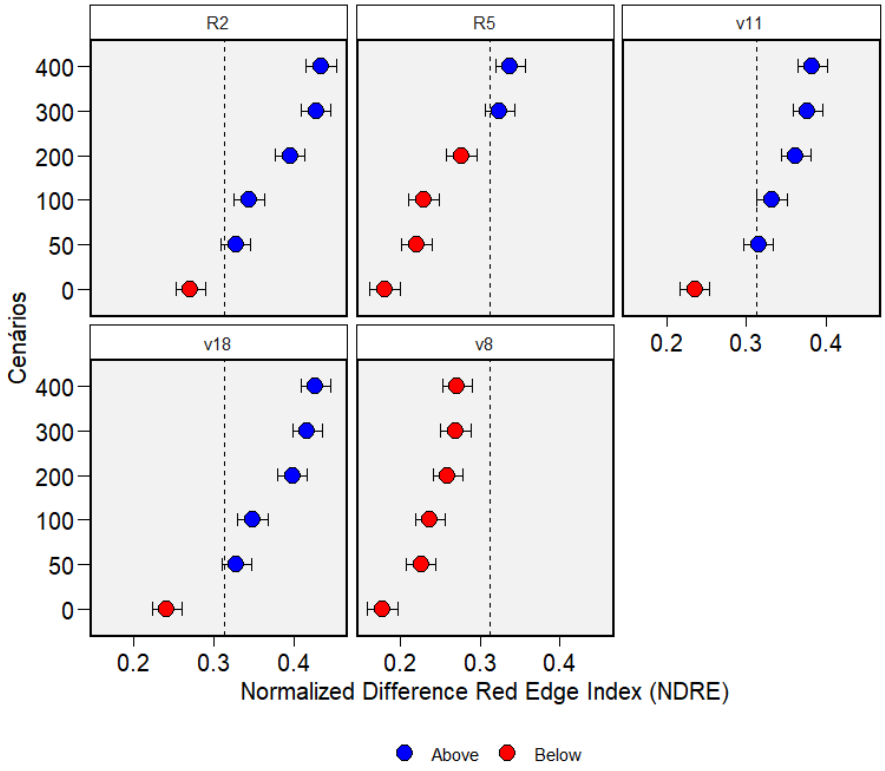


FIGURA 3. Análise de BLUP com os dados de cenários preditos para o índice NDRE.

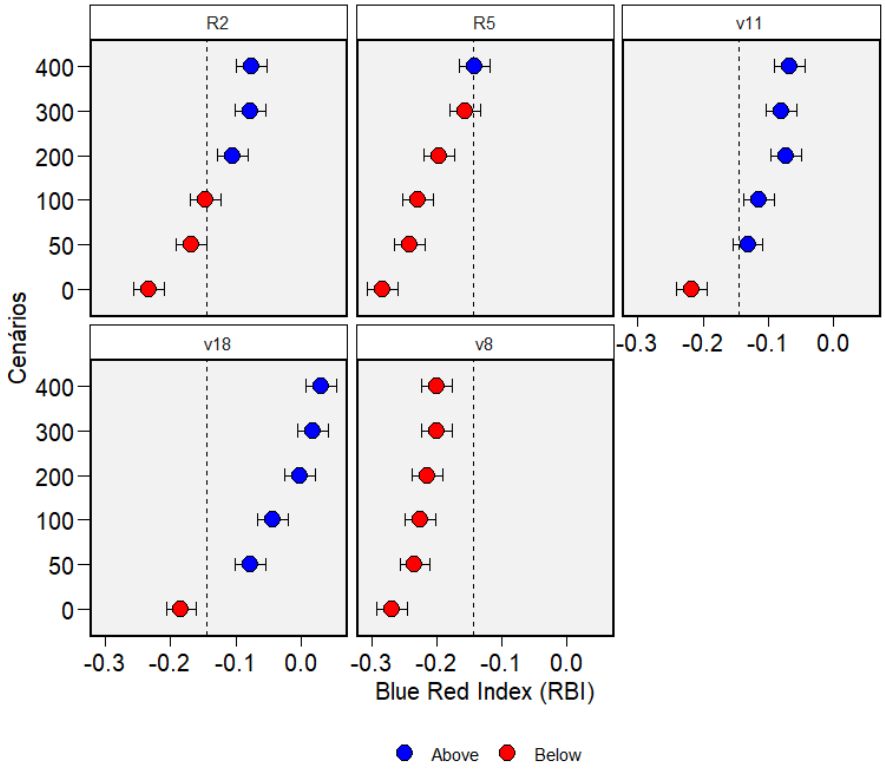


FIGURA 4. Análise de BLUP com os dados de cenários preditos para o índice RBI.

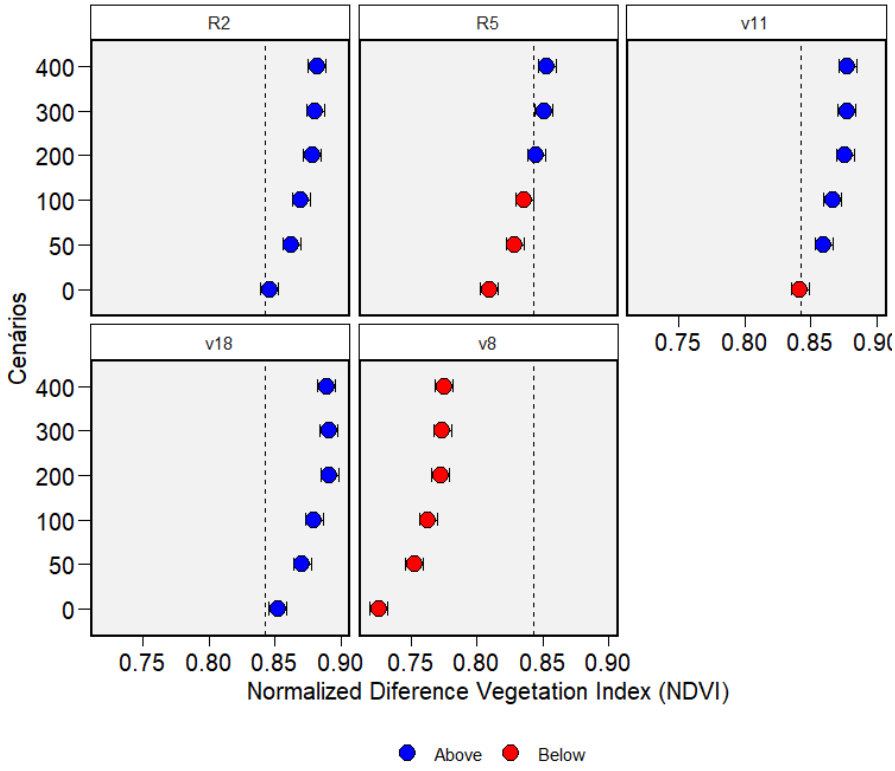


FIGURA 5. Análise de BLUP com os dados de cenários preditos para o índice NDVI - VANT.

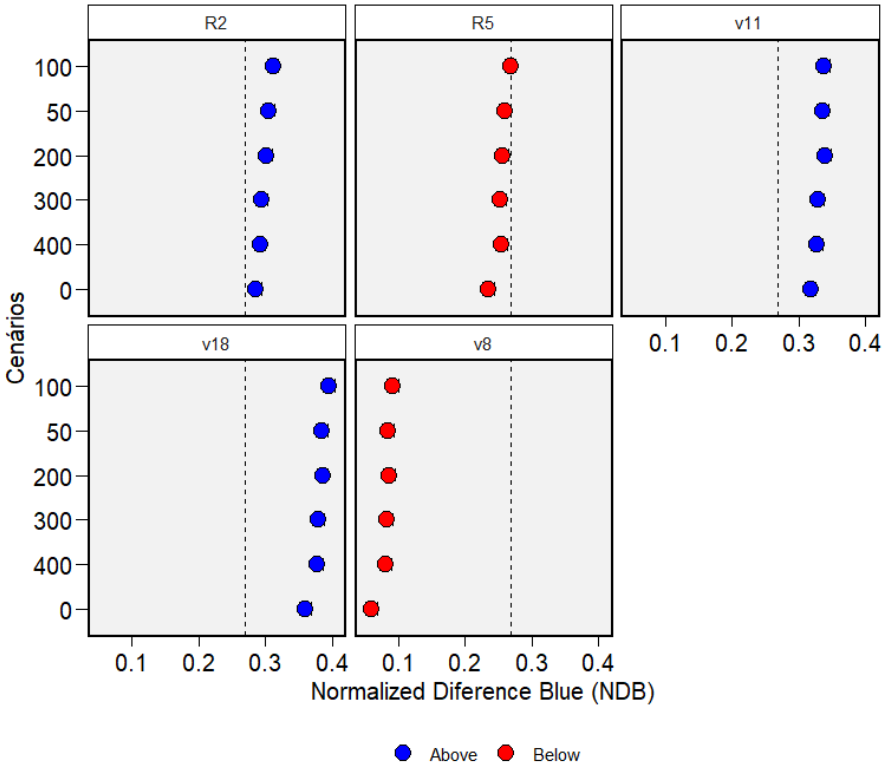


FIGURA 6. Análise de BLUP com os dados de cenários preditos para o índice NDB.

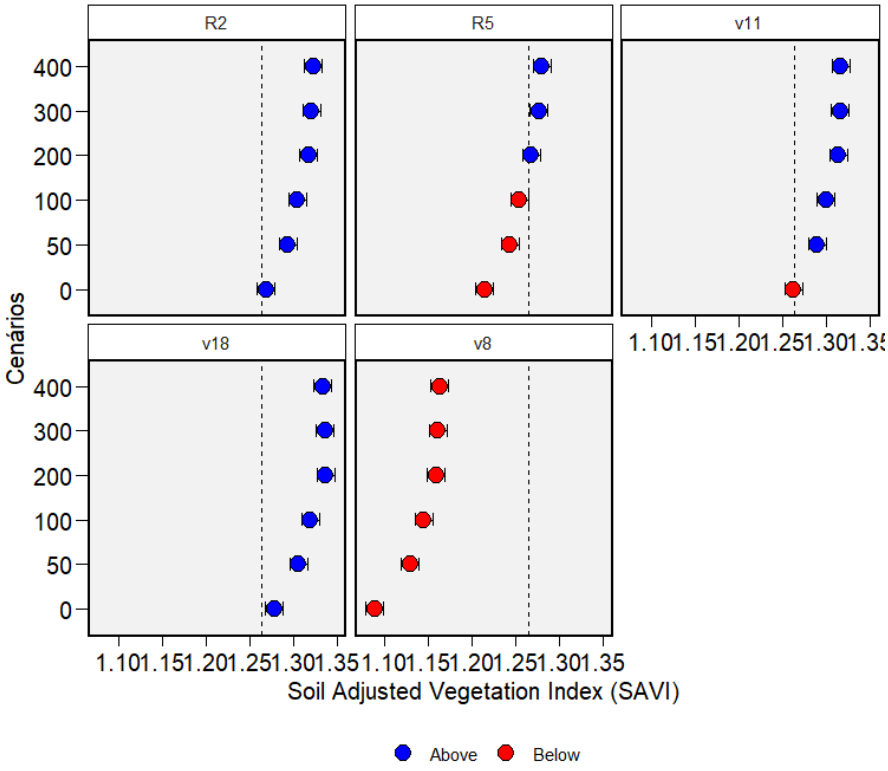


FIGURA 7. Análise de BLUP com os dados de cenários preditos para o índice SAVI.

De acordo com a metodologia RELM-BLUP, índices como o NDB, NDVI e SAVI, não apresentaram resultados consistentes na avaliação dos cenários nos diferentes voos (Figura 5, 6 e 7), com menor herdabilidade e maior contribuição do erro experimental, observada pela relação CVc/CVe. O que

reduziu a sensitividade dos índices as modificações da vegetação ao longo do ciclo, indicando uma saturação precoce dos índices em doses baixas de N e logo após o estádio v8. Tais resultados corroboram com Rehman et al. (2022), os quais avaliaram a capacidade de saturação dos índices NDVI obtido com VANT, NDVI proximal (greenseeker) e NDRE na cultura do arroz. Tais autores observaram que o NDVI do VANT apresentou saturação sob baixas doses de N, com menor magnitude de efeitos na predição do rendimento de grãos. Além disso, NDVI proximal e NDRE demonstraram maior resistência a saturação, o que justifica a resposta significativa de tais parâmetros na análise de máxima verossimilhança e componentes da variância (Tabela 2).

O fenômeno de saturação é um problema conhecido no sensoriamento remoto, o qual pode ser atribuído a saturação da reflectância e tipo de formulação matemática (MUTANGA et al., 2023). No caso de índices com NDB, NDVI, SAVI, EVI e DVI, o pico de absorção das clorofilas nos comprimentos de onda do vermelho e azul gera uma insensibilidade ao incremento gradual de área foliar e biomassa em condições de cobertura total do solo (GAO et al., 2023). Contudo, a reflectância do verde ou infravermelho continua aumentando, o que gera um desbalanço no cálculo matemático e leves modificações nos valores absolutos (THENKABAIL et al., 2000). Obtendo-se melhor caracterização de parâmetros morfológicos quando se utiliza índices com múltiplas bandas espectrais ou formulação com bandas menos discrepantes (GAO et al., 2023), o que corrobora com os resultados encontrados para os índices EXR, GRVI, NDRE e RBI (Tabela 2, Figura 3 e 4). Neste sentido, Adak et al. (2021) realizaram a decomposição dos componentes de variância via RELM-BLUP para 16 índices de vegetação e fatores associados a genótipos de milho, momento do voo e época de semeadura. Tais autores observaram que a avaliação temporal (voos) pode contribuir com até 80% na variação dos resultados, obtendo-se maior estabilidade ao longo do ciclo para os índices GRVI e GLI, similar aos resultados obtidos no presente estudo (Tabela 2).

A partir dos valores obtidos via RELM-BLUP, aplicou-se um modelo linear simples para a predição de variáveis fitomorfológicas, 70% dos dados para treino e 30% teste. Com seleção de índices baseado na significância dos parâmetros pela regressão stepwise. Logo, constatou-se que, a predição das variáveis biomassa, altura e nitrogênio no tecido utilizando a metodologia RELM-BLUP proporcionou um coeficiente de determinação de 0,89; 0,96 e 0,82, respectivamente (Figura 8). Superior ao modelo ajustado sem a utilização da metodologia, além de menor erro médio quadrático (RMSE) para todas as variáveis preditas. Tais resultados estão diretamente ligados a remoção do efeito ambiental nos valores coletados e atribuição apenas do efeito de tratamento (CARVALHO et al., 2018). O que garante maior acurácia na predição de variáveis pela dedução dos efeitos fixos e aleatórios nas respostas (GUO et al., 2020), sem a necessidade de aplicar modelos mais complexos.

Embora a metodologia RELM-BLUP seja aplicada preferencialmente na análise de dados genéticos sob diferentes ambientes, a utilização da metodologia para a quantificação e remoção dos efeitos associados a fatores ambientais como o estádio fenológico torna-se imprescindível, independentemente do tipo de pesquisa. Logo, a aplicação da técnica permite a seleção de variáveis que representam adequadamente as modificações da vegetação ao longo do ciclo, além de melhorar a predição de parâmetros fitomorfológicos.

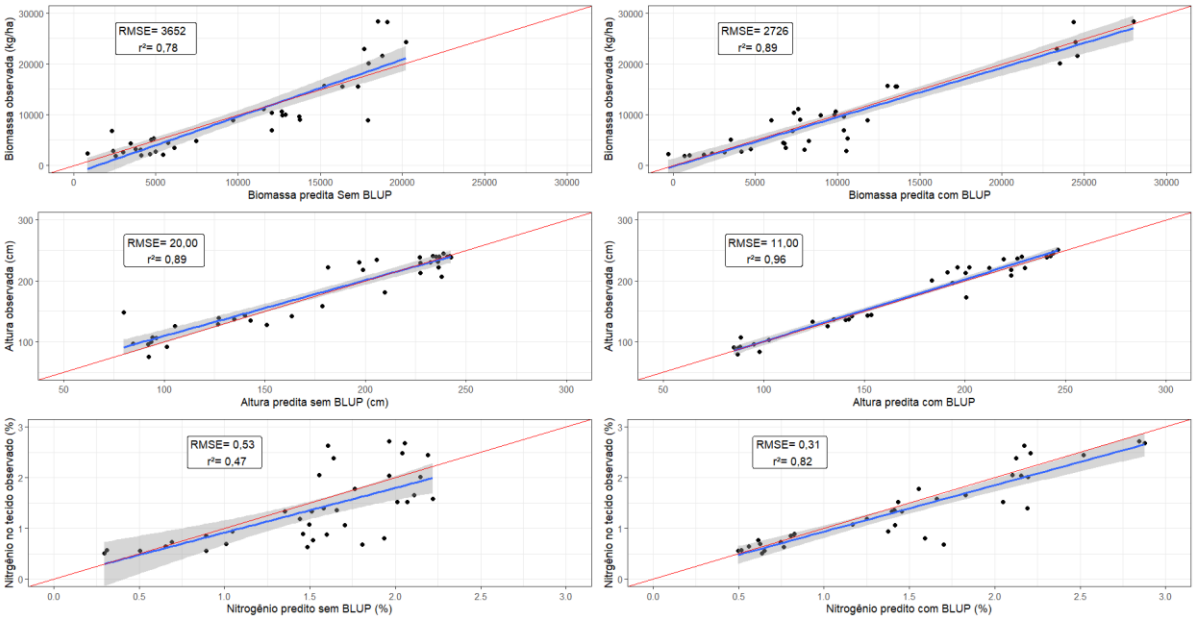


FIGURA 8. Análise com dados preditos e observados sem e com a metodologia BLUP.

CONCLUSÃO

Conclui-se que, a metodologia RELM-BLUP pode ser aplicada para a seleção de melhores parâmetros, com redução da influência voo (estádio fenológico) a partir dos novos valores obtidos pela metodologia. Além do incremento na acurácia das predições, com maior contribuição de índices que apresentam efeito significativo para a interação cenários x voos e menor fenômeno de saturação.

REFERÊNCIAS

ABRAHAMS, M.; SIBANDA, M.; DUBE, T.; CHIMONYO, V. G. P.; MABHAUDHI, T. A systematic review of UAV applications for mapping neglected and underutilised crop species' spatial distribution and health. **Remote Sensing**, v. 15, p. 1-31, 2023. Doi: 10.3390/rs15194672

ADAK, A.; MURRAY, S. C.; BOZINOVIC, S.; LINDSEY, R.; NAKASAGGA, S.; CHATTERJEE, S.; ANDERSON, S. L.; WILDE, S. Temporal vegetation indices and plant height from remotely sensed imagery can predict grain yield and flowering time breeding value in maize via machine learning regression. **Remote Sensing**, v. 13, p. 1-21, 2021.

ARGENTA, G.; FERREIRA DA SILVA, P. R.; SANGOI, L. Leaf relative chlorophyll content as an indicator parameter to predict nitrogen fertilization in maize. **Ciência Rural**, v. 34, n. 5, p. 1379-1387, 2004.

BAPTISTA, G. M. M. Aplicação do índice de vegetação por profundidade de feição espectral (SFDVI - spectral feature depth vegetation index) em dados rapideye. **Anais XVII Simpósio Brasileiro de Sensoriamento Remoto**, p. 2277-2284, 2015.

CARVALHO, I. R.; SZARESKI, V. J.; MAMBRIN, R. B.; FERRARI, M.; PELEGRIN, A. J.; ROSA, T. C.; PETER, M.; SILVEIRA, D. C.; CONTE, G. C.; BARBOSA, M. H.; SOUZA, V. Q. Biometric models and maize genetic breeding: A review. **Australian Journal of Crop Science**, v. 12, p. 1796-1805, 2018. doi: 10.21475/ajcs.18.12.11.p792

CHEN, D.; SHI, R.; PAPE, J.; NEUMANN, K.; AREND, D.; GRANER, A.; CHEN, M.; KLUKAS, C. Predicting plant biomass accumulation from image-derived parameters. **GigaScience**, v. 7, p. 1-13, 2018.

CHIVASA, W.; MUTANGA, O.; BURGUENO, J. UAV-based high-throughput phenotyping to increase prediction and selection accuracy in maize varieties under artificial MSV inoculation. **Computers and Electronics in Agriculture**, v.184, p. 1-14, 2021. Doi: 10.1016/j.compag.2021.106128

FLINT-GARCIA, S. A. et al. Maize association population: a high-resolution platform for quantitative trait locus dissection. **The Plant Journal**, v. 44, p. 1054 - 1064, 2005.

GAO, S.; ZHONG, R.; YAN, K.; MA, X.; CHEN, X.; PU, J.; GAO, S.; QI, J.; YIN, G.; MYNENI, R. B. Evaluating the saturation effect of vegetation indices in forests using 3D radiative transfer simulations and satellite observations. **Remote Sensing of Environment**, v. 295, p. 1-18, 2023. Doi: 10.1016/j.rse.2023.113665

GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a Green Channel in Remote Sensing of

Global Vegetation from EOS-MODIS. **Remote Sensing of Environment**, v. 58, p. 289-298, 1996.

GITELSON, A. A.; VINA, A.; ARKEBAUER, T. J.; RUNDQUIST, D. C.; KEYDAN, G.; LEAVITT, B. Remote estimation of leaf area index and green leaf biomass in maize canopies. **Geophysical Research Letters**, v. 30, p. 335-443, 2003. Doi: 10.1029/2002gl016450

GUO, J.; PRADHAN, S.; SHAHI, D.; KHAN, J.; MCBREEN, J.; BAI, G.; MURPHY, J. P.; BABAR, M. A. Increased prediction accuracy using combined genomic information and physiological traits in a soft wheat panel evaluated in multi-environments. **Scientific reports**, v. 10, p. 1-12, 2020. Doi: 10.1038/s41598-020-63919-3

GUO, Y.; WANG, H.; WU, Z.; WANG, S. et al. modified red blue vegetation index for chlorophyll estimation and yield prediction of maize from. **Sensors**, v. 20, p. 1-16, 2020. Doi: 10.3390/s20185055

HAGUE, T.; TILLETT, N. D.; WHEELER, H. Automated crop and weed monitoring in widely spaced cereals. **Precision Agriculture**, v. 7, p. 21-32, 2006. Doi: 10.1007/s11119-005-6787-1.

HUETE, A. R.; HUA, G.; QI, J.; CHEHBOUNI, A. normalization of multidirectional red and nir reflectances with the SAVI. **Remote Sensing of Environment**, v. 41, p. 143-154, 1992.

JIANG, Z.; HUETE, A. R.; DIDAN, K.; MIURA, T. Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, v. 112, p. 3833-3845, 2008.

KATAOKA, T.; KANEKO, T.; OKAMOTO, H.; HATA, S. Crop growth estimation system using machine vision; Proceedings of the IEEE/ASME. **International Conference on Advanced Intelligent Mechatronics**, p. 1079-1083, 2003.

LOUHAICHI, M.; BORMAN, M. M.; JOHNSON, D. E. Spatially located platform and aerial photography for documentation of grazing impacts on wheat. **Geocarto International**, v. 16, p. 65-70, 2001. Doi: 10.1080/10106040108542184.

MA, H.; LI, X.; JI, J.; CUI, H.; SHI, Y.; LI, N.; YANG, C. Monitoring indicators for comprehensive growth of summer maize based on UAV remote sensing. **Agronomy**, v. 13, p. 1-17, 2023. Doi: 10.3390/agronomy13122888

MEYER, G. E.; NETO, J. C. Verification of color vegetation indices for automated crop imaging applications. **Computers and Electronics in Agriculture**, v. 63, p. 282-293, 2008. Doi: 10.1016/j.compag.2008.03.009.

MUTANGA, O.; MASENYAMA, A.; SIBANDA, M. Spectral saturation in the remote sensing of high-density vegetation traits: A systematic review of progress, challenges, and prospects. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 198, p. 297-309, 2023. Doi: 10.1016/j.isprsjprs.2023.03.010

OLIVOTO, T.; LÚCIO, A. D. C.; SILVA, J. A. D. SARI, B. G.; DIEL, M. I. Mean performance and stability in multi-environment trials ii: selection based on multiple traits. **Agronomy Journal**, v. 111, p. 2961 - 2969, 2019.

RESENDE, M. D. V. Software Selegen-REML/BLUP: a useful tool for plant breeding. **Crop Breeding and Applied Biotechnology**, v. 6, p. 330 - 339, 2016.

ROBERTSON, A. N.; GITELSON, A.; PENG, Y.; VINA, A. et al. Green leaf area index estimation in maize and soybean: combining vegetation indices to achieve maximal sensitivity. **Agronomy Journal**, v. 104, p. 1336-1347, 2012.

RODRIGUEZ, D.; FITZGERALD, G. J.; BELFORD, R.; CHRISTENSEN, L. K. Detection of nitrogen deficiency in wheat from spectral reflectance indices and basic crop eco-physiological concepts. **Australian Journal of Agricultural Research**, v. 57, p. 781-789, 2006.

SHRESTHA, A.; BHEEMANAHALLI, R.; ADELI, A.; SAMIAPPAN, S.; CZARNECKI, J. M. P.; MCCRAINE, C. D.; REDDY, K. R.; MOORHEAD, R. Phenological stage and vegetation index for predicting corn yield under rainfed environments. **Frontiers in Plant Science**, v. 14, p. 1-12, 2023. Doi: 10.3389/fpls.2023.1168732

SUN, X.; YANG, Z.; SU, P.; WEI, K.; WANG, Z.; YANG, C.; WANG, C.; QIN, M.; XIAO, L.; YANG, W.; ZHANG, M.; SONG, X.; FENG, M. Nondestructive monitoring of maize LAI by fusing UAV spectral and textural features. **Frontiers in Plant Science**, v. 14, p. 1-11, 2023. Doi: 10.3389/fpls.2023.1158837

THENKABAIL, P. S.; SMITH, R. B.; PAUW, E. D. Hyperspectral vegetation indices and their relationships with agricultural crop characteristics. **Remote Sensing of Environment**, v. 71, p. 158-182, 2000.

TUCKER, C. J. Monitoring corn and soybean crop development with hand-held radiometer spectral data. **Remote sensing of environment**, v. 8, p. 237-247, 1979.

WANG, F.; HUANG, J.; TANG, Y.; WANG, X. New vegetation index and its application in estimating leaf area index. **Rice Science**, v. 14, p. 195-203, 2007.

WOEBBECKE, D. M.; MEYER, G. E.; BARGEN, K. V.; MORTENSEN, D. A. Color indices for weed identification under various soil, residue, and lighting conditions. **Transactions of the ASAE**, v. 38, p. 259-269, 1994. doi: 10.13031/2013.27838.

YANG, B.; ZHU, W.; REZAEI, E. E.; LI, J.; SUN, Z.; ZHANG, J. The Optimal phenological phase of maize for yield prediction with high-frequency UAV remote sensing. **Remote Sensing**, v. 14, p. 1-18, 2022. Doi: 10.3390/rs14071559

IMPACTO DO MÉTODO DE INTERPOLAÇÃO EM SITUAÇÃO DE LIMITAÇÃO AMOSTRAL NOS MAPAS DE PRESCRIÇÃO DE FERTILIZANTES

Lucas Rios do Amaral [1]; Derlei Dias Melo [2]; Laura Delgado Bejarano [2]; Thiago Luis Brasco [3]; Henrique Oldoni [4]

[1]Docente. Av. Cândido Rondon, 501 - Barão Geraldo 13083-875 - Campinas/SP. Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas (FEAGRI/UNICAMP); [2]Mestrando. Av. Cândido Rondon, 501 - Barão Geraldo 13083-875 - Campinas/SP. Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas (FEAGRI/UNICAMP); [3]Técnico. Av. Cândido Rondon, 501 - Barão Geraldo 13083-875 - Campinas/SP. Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas (FEAGRI/UNICAMP); [4]Pós-doutorando. Rua Cora Coralina, 330 - Barão Geraldo 13083-896 - Campinas/SP. Núcleo Interdisciplinar de Planejamento Energético, Universidade Estadual de Campinas (NIPE/UNICAMP)

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A amostragem de solo em baixa densidade é uma realidade na agricultura de precisão brasileira. Dessa forma, é preciso identificar as melhores práticas para que o agricultor e os prestadores de serviço consigam extrair o máximo resultado do investimento realizado no mapeamento do solo. Assim, este estudo avaliou o impacto dos métodos de interpolação nos mapas de prescrição de fertilizantes em situações onde a densidade amostral é restritiva, buscando determinar se há um método mais indicado nesse tipo de situação. Utilizamos uma área cultivada com cana-de-açúcar de 72 ha, coletando 450 amostras de solo, mas usando apenas 38 delas para gerar os mapas de prescrição de fertilizantes (P e K) por cinco métodos de interpolação distintos. Devido a baixa dependência espacial das propriedades do solo, a krigagem ordinária suavizou demasiadamente os mapas resultantes, comprometendo o resultado da aplicação em doses variadas. Os métodos multivariados (SVM e KED), embora tenham grande potencial, não apresentaram bom desempenho devido a baixa relação dos teores de P e K com os valores de suscetibilidade magnética do solo. O método de *spline* utilizado neste trabalho (*Thin Plate Spline*) foi o que mais honrou as classes de disponibilidade dos nutrientes no solo e precisa ser mais explorado em estudos futuros.

PALAVRAS-CHAVE: Krigagem; Spline; Amostragem de solo

ABSTRACT

Low-density soil sampling is a reality in Brazilian precision agriculture. Therefore, it is necessary to identify the best practices so that the farmer and service providers can extract the maximum result from the investment made in soil mapping. Thus, this study evaluated the impact of interpolation methods on fertilizer prescription maps in situations where sampling density is restrictive, seeking to determine whether a more suitable method exists in this type of situation. We used a 72 ha sugarcane cultivated area, collecting 450 soil samples, but only 38 of them were used to generate fertilizer prescription maps (P and K) using five different interpolation methods. Due to the low spatial dependence of soil properties, ordinary kriging excessively smoothed the resulting maps, compromising the results of variable-rate application. Although the multivariate methods (SVM and KED) have great potential, they did not perform well due to the low relationship between P and K contents and the soil magnetic susceptibility. The Spline method used in this study (Thin Plate Spline) was the one that best honored the nutrient availability classes in the soil and needs to be further explored in future studies.

KEYWORDS: ;

INTRODUÇÃO

A agricultura de precisão preconiza a quantificação da variabilidade espacial e temporal dos fatores de produção, de forma que o manejo geolocalizado permita a otimização do uso de recursos e aumento da rentabilidade ao agricultor (Gebbers e Adamchuk, 2010). Nesse sentido, a aplicação de fertilizantes em doses variadas é a técnica mais difundida. Para tal, os mapas de prescrição são construídos a partir de uma amostragem georreferenciada de solo, geralmente oriunda de uma grade regular. Contudo, devido aos custos envolvidos no processo de amostragem e na análise do solo em laboratório, frequentemente a densidade amostral é aquém da que deveria ser para quantificar adequadamente a variabilidade espacial das propriedades químicas do solo (Cherubin et al., 2014; Nanni et al., 2011). Isso faz com que os mapas de prescrição contenham erros e, por consequência, comprometa os possíveis retornos dessa técnica.

É consenso que a krigagem é o método de interpolação mais recomendado para dados geoespaciais, inclusive para dados de solo em agricultura de precisão (Oliver, 2010). No entanto, frequentemente o número mínimo de amostras e a baixa densidade amostral inviabilizam a aplicação desse método ou comprometem significativamente seu desempenho (Amaral e Justina, 2019; Nanni et al., 2011). Buscando superar essa limitação, diversos trabalhos buscam métodos de otimizar o planejamento amostral (Vasát et al., 2010; Pusch et al., 2023) e o processo de interpolação espacial em si (Pusch et al., 2021, 2022). Entretanto, por demandar análises complexas e coleta sistemática de dados, tais soluções praticamente não são adotadas na prática de campo. Assim, é preciso investigar como os agricultores e prestadores de serviço conseguiriam extrair o melhor resultado possível em termos de mapeamento do solo assumindo densidade amostral esparsa, algo como 2 a 5 hectares por amostra, que são as densidades mais amplamente utilizadas no Brasil (Molin, 2017), ao mesmo tempo que aliam a praticidade na confecção dos mapas.

OBJETIVOS

Desse modo, este estudo buscou inferir a influência dos métodos de interpolação nos mapas de prescrição de fertilizantes e determinar se há um método mais indicado na situação em que a densidade amostral e o número de amostras são baixos.

MATERIAL E MÉTODOS

O estudo foi realizado em área produtora de cana-de-açúcar de 72 ha localizada no interior de São Paulo, com predominância de um Latossolo vermelho de textura argilosa. A amostragem de solo foi realizada por meio de quadriciclo instrumentado com broca, coletando 6 subamostras num raio de 5 m do ponto central. A camada amostrada de solo foi de 0-25 cm de profundidade e realizada após o décimo corte da soqueira, antes do manejo para reforma do canavial. No total, foram coletadas 450 amostras compostas, resultando numa densidade de 6 amostras por hectare (Figura 1). Neste trabalho, como o foco é na prescrição de fertilizantes, trabalhamos com os teores de fósforo (P) e potássio (K) disponíveis, ambos quantificados em laboratório por meio de resina trocadora de íons.

Buscando exemplificar uma situação real de amostragem de solo e prescrição de fertilizantes em doses variadas no Brasil, 38 amostras foram selecionadas a partir da grade original densa, simulando uma grade regular com densidade aproximada de 2 hectares por amostra (Figura 1). Os demais pontos foram usados como pontos de validação para as diferentes estratégias de interpolação utilizadas.

Neste estudo exploramos cinco métodos de interpolação, sendo dois deles determinísticos, dois estocásticos e um baseado em aprendizagem de máquina:

· Inverso do Quadrado da Distância (IDW): este é um método determinístico (Li e Heap, 2011) que apresenta implementação simples e é amplamente utilizado em softwares dedicados à agricultura de precisão.

· *Thin Plate Spline* (TPS): é um método determinístico da classe dos *splines*, que são basicamente suavizadores baseados em janelas móveis. Ainda é pouco explorado na agricultura de precisão, mas já há plataformas digitais que utilizam este método como padrão para interpolação.

· Krigagem ordinária (KO): é o interpolador estocástico mais indicado para predições espaciais de uma única variável (Oliver, 2010), com o diferencial de demandar a modelagem variográfica antes do processo de interpolação.

· Krigagem com deriva externa (KED): é um tipo de krigagem, mas que se utiliza de uma ou mais variáveis densamente amostrada e que tenha relação com a variável de interesse para modelar a tendência (ou deriva) e, em seguida, modelar o variograma dos resíduos dessa regressão entre variável principal e auxiliares (Goovaerts e Kerry, 2010).

· *Support Vector Machine* (SVM): é um algoritmo de aprendizagem de máquina supervisionado, o qual é calibrado por meio da colocalização dos valores da variável auxiliar nos locais onde a variável de interesse também foi amostrada. Kerry et al (2024) usou uma regressão linear com objetivo semelhante, mas aqui optamos por usar o SVM buscando melhores resultados, já que Pereira et al. (2022) reportaram sua superioridade em comparação à KO e IDW.

As interpolações por IDW e TPS foram realizadas por rotina nativa no QGIS 3.34, enquanto o SVM foi implementado a partir do plugin Smart-Map instalado no QGIS (Pereira et al., 2022). A KO e a KED foram realizadas por meio do pacote *gstat* no ambiente R. Todos os arquivos matriciais foram criados com resolução de 5x5 m. No caso de SVM e KED que se utilizam de variável auxiliar, utilizamos a suscetibilidade magnética do solo (SM) mensurada até 0,75 m de profundidade com o sensor EM-38 MK2 (Geonics, Canadá), tracionado por quadriciclo com velocidade aproximada de 20 km h^{-1}, o que gerou pontos a cada ~6 m no sentido de deslocamento e com espaçamento de 15 m entre as passadas (Figura 2). Para a KED, o dado de SM foi interpolado por KO, de forma que em cada pixel de interpolação houvesse valores de SM (Figura 2); já para o SVM, os dados pontuais foram colocalizados com os pontos de solo por meio de um buffer traçado pelo próprio complemento e, então, o modelo foi automaticamente treinado.

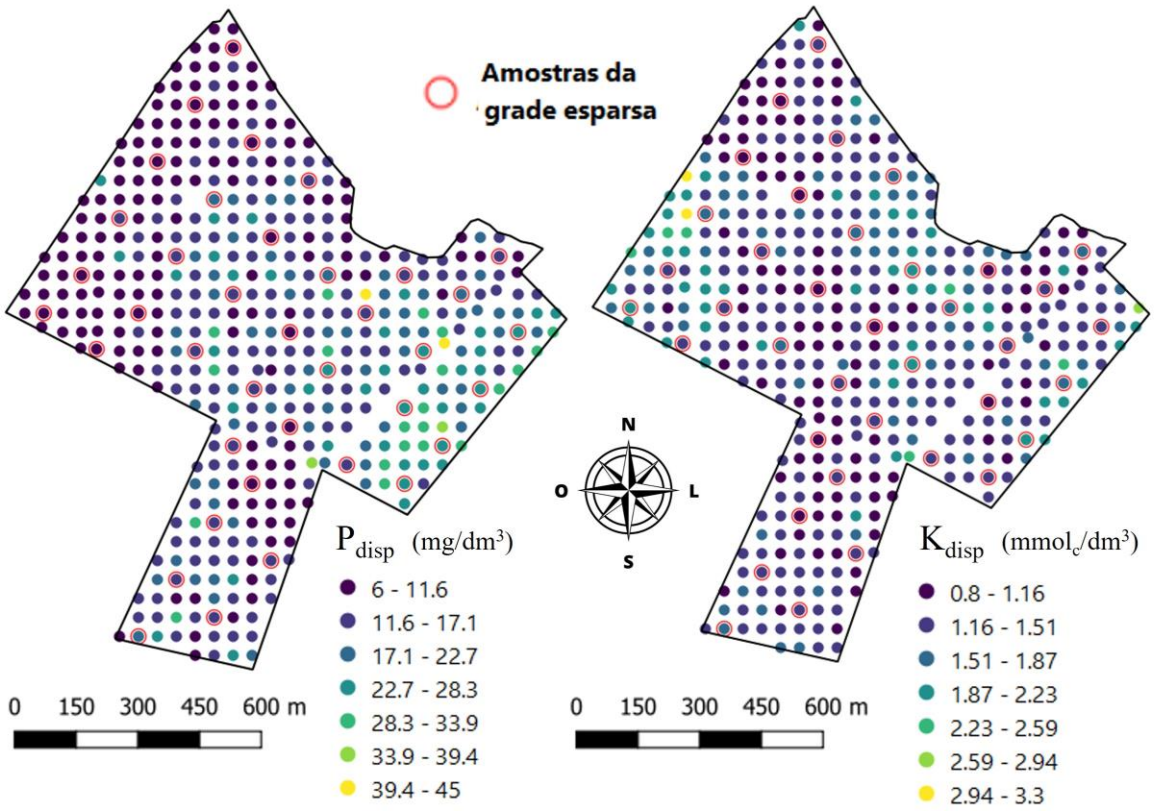


FIGURA 1. Pontos de amostragem de solo e valores de P e K disponíveis, destacando os pontos usados nas interpolações (círculos vermelhos - grade esparsa), sendo os demais usados como validação

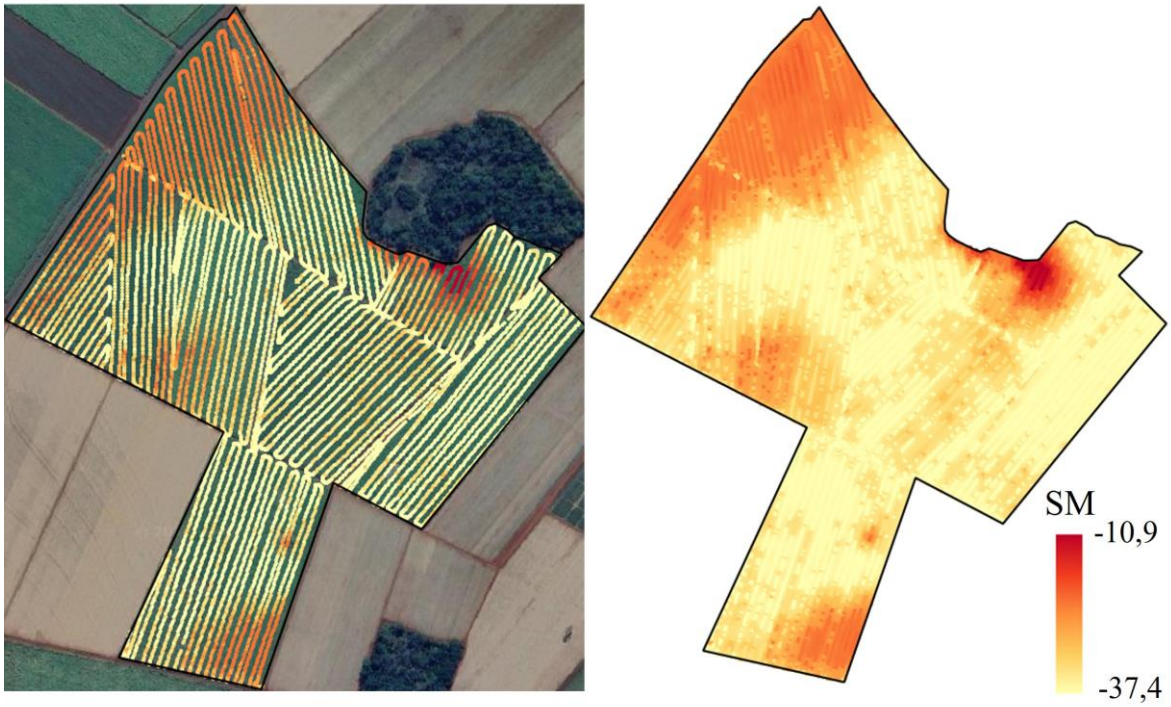


FIGURA 2. Leituras de suscetibilidade magnética do solo (SM - esquerda) e mapa construído a partir da krigagem ordinária para ser usado como variável auxiliar na KED (direita)

Como o objetivo foi quantificar o impacto das interpolações na prescrição de fertilizantes, os teores de P e K no solo foram convertidos para doses de fertilizante fosfatado (P_2O_5) e potássico (K_2O), seguindo tabela de recomendação para plantio de cana-de-açúcar com produtividade esperada de 100 a 130 t ha^{-1}, disponível em Cantarella et al (2022). Assumimos o valor intermediário de cada classe

de disponibilidade para integrar a dose recomendada e, com isso, geramos as equações de recomendação abaixo, as quais foram aplicadas nos mapas de fertilidade e nas amostras de validação. No caso do cálculo do dose média recomendada para a área, calculamos a média dos teores de P e K para todas as amostras de validação e, em seguida, aplicamos a equação de prescrição.

Dose de P_2O_5 (kg ha^{-1}) = -3.5887*P_{solo} + 202.16 (Eq. 1)

Dose de K_2O (kg ha^{-1}) = -32.537*K_{solo} + 183.97 (Eq. 2)

A dependência espacial dos dados, tanto da grade densa de referência quanto da grade esparsa efetivamente usada para interpolação, foi inferida pelo Índice de Moran, obtido no plugin Smart-Map. Além disso, tal dependência também pode ser constatada por meio dos ajustes dos variogramas e os resultados da validação cruzada dos modelos. Para os dados em estudo, o modelo esférico foi o que mais se ajustou em todas as situações. Os teores de P e K interpolados pelos diferentes métodos foram comparados pela correlação de Spearman nos pontos de validação (n = 412) e as classes de disponibilidade dos nutrientes (Cantarella et al, 2022) foram definidas para cada amostra de validação, de forma a permitir o cálculo do índice de concordância Kappa. Além disso, o plugin Profile Tool do QGIS foi usado para traçar um transecto nos mapas de prescrição obtidos e, assim, comparar os perfis de distribuição das doses recomendadas.

RESULTADOS E DISCUSSÃO

A fertilidade química da área de estudo apresenta dependência espacial reduzida, ou seja, grande parte da variabilidade dos dados não é função de sua localização, o que pode ser verificado pelo resultado mediano da validação cruzada da krigagem ordinária (Tabela 1), mesmo para o conjunto denso de dados (i.e., 450 amostras, 6 amostras por hectare); isso mostra que nem sempre a alta densidade amostral gera bons mapas de fertilidade. O Índice de Moran mostrou que a amostragem esparsa usada para as interpolações apresentou agrupamento espacial para os dados de P ($p < 0,05$), mas o mesmo não ocorreu para os dados de K. Com isso, a mensuração da dependência espacial da grade esparsa pelos variogramas ficou comprometida (Tabela 1), comprometendo o resultado de qualquer método de interpolação espacial que seja usado. Isso ficou comprovado pelas correlações entre os valores medidos nos pontos de validação e os preditos pelos métodos de interpolação (Tabela 2), onde os resultados para P foram melhores, independente do método utilizado. Essa baixa dependência espacial em amostragens esparsas de solo é frequentemente observada (Santos et al., 2018), o que torna os resultados deste estudo generalizáveis para outras situações, independentemente da propriedade do solo analisada.

TABELA 1. Agrupamento espacial medido pelo índice de Moran (IM) e sua significância (*p*), parâmetros dos variogramas (*a*: alcance - m, c0: efeito pepita, c1: contribuição, e relação c1 e patamar) e da validação cruzada (r2: coeficiente de determinação e RMSE: raiz quadrada do erro quadrático médio entre predito e observado) para os valores de P e K disponíveis, tanto para o conjunto esparso selecionado para interpolação quanto o conjunto de dados denso original

Atributo	Grade	IM	*p*	*a*	c0	c1	c1/(c0+c1)	r2	RMSE
P	Esparsa	0,769	<0,001	310	4,5	13,5	0,75	0,520	4,17
	Densa	0,644	<0,001	240	11,0	15,0	0,58	0,533	4,39
K	Esparsa	0,458	0,395	320	0,079	0,035	0,31	0,023	0,336
	Densa	0,547	<0,001	300	0,045	0,075	0,63	0,342	0,299

TABELA 2. Correlação de Spearman dos valores de P e K para os pontos de validação em função do método de interpolação. Na perpendicular superior (texto em azul) estão os valores de coeficiente de

correlação para o P, enquanto na perpendicular inferior (texto vermelho e em itálico) estão os valores para K

	Teor solo (K)	IDW	TPS	KO	SVM	KED
Teor solo (P)		**0,68**	**0,70**	**0,69**	**0,59**	**0,71**
IDW	***0,44***		0,94	0,97	0,86	0,92
TPS	***0,45***	*0,94*		0,94	0,75	0,93
KO	***0,46***	*0,88*	*0,84*		0,87	0,92
SVM	***0,33***	*0,77*	*0,67*	*0,86*		0,80
KED	***0,42***	*0,90*	*0,90*	*0,89*	*0,82*	

A krigagem possui a característica de suavizar as predições quando a dependência espacial é baixa, já que a incerteza onde não existe observações de campo é alta. Isso fica evidente nos mapas das Figuras 3 e 4, mas ainda mais no perfil das doses na Figura 5. Como o P apresentou maior agrupamento espacial do que o K (Tabela 1), é possível observar menor suavização nas doses de P, se assemelhando mais aos métodos determinísticos (IDW e TPS). Essa suavização visa reduzir as incertezas nas predições e sua variância, o que é interessante para algumas finalidades (Soares, 2014); porém, com vistas a aplicação variada de fertilizantes, isso faz com que as variações de doses sejam muito pequenas, chegando a torná-las até mesmo insignificantes em termos de amplitude das doses, não justificando todo o investimento realizado no levantamento. Esse é o principal problema de se trabalhar com uma amostragem que não capture adequadamente a variabilidade espacial dos dados. Sendo assim, nesse cenário de poucas amostras ou de baixa dependência espacial, os interpoladores determinísticos podem ser preferidos. Fica evidente na Figura 6 que a distribuição dos erros de dose resultantes dos diferentes métodos de interpolação são semelhantes; contudo, se fosse considerado uma única dose uniforme para todo o talhão (P2O5: 148 kg ha^{-1}; K2O: 138 kg ha^{-1}), os erros seriam maiores. Assim sendo, como o manejo em doses variáveis se justifica, mas os erros das predições seriam altos de qualquer modo, ao menos teriam-se mapas de prescrição que minimamente mantem a amplitude das doses observadas nas coordenadas dos pontos amostrais quando se trabalha com os métodos determinísticos, diferentemente dos mapas suavizados oriundos da krigagem.

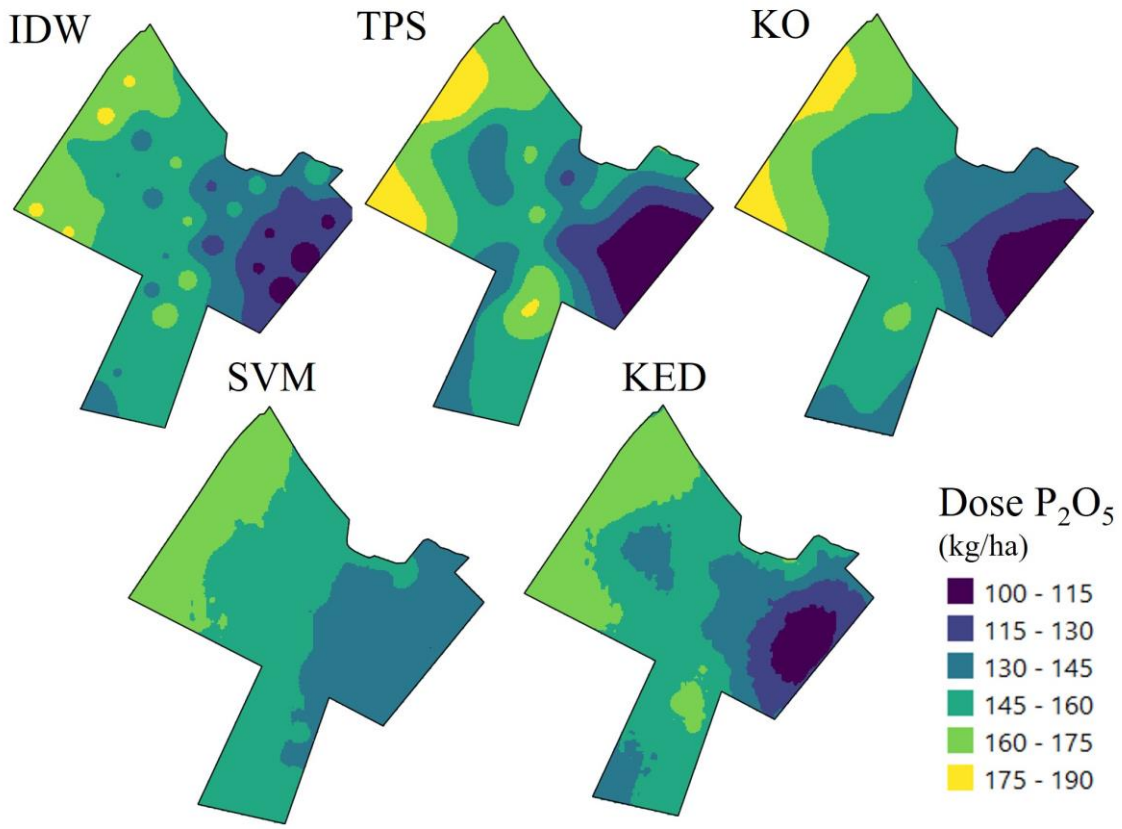


FIGURA 3. Mapas de prescrição de fertilizante fosfatado (P2O5) em função do método de interpolação

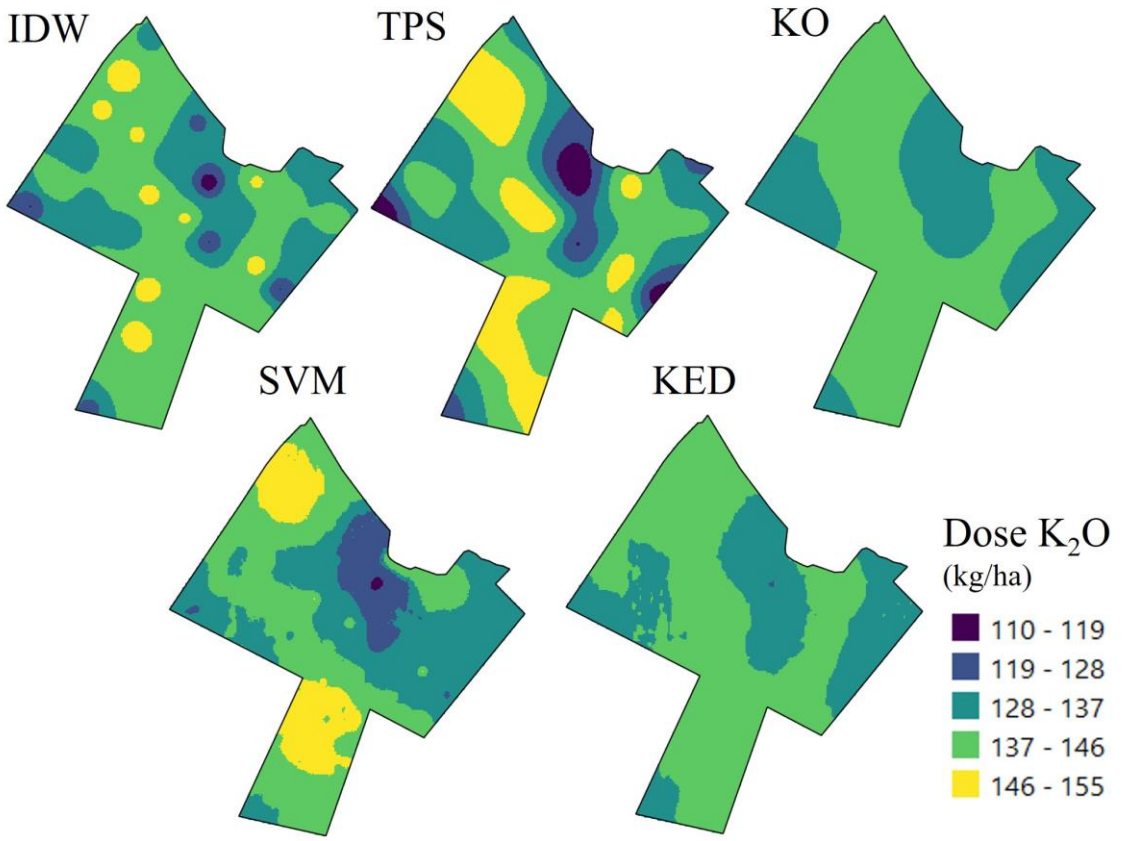


FIGURA 4. Mapas de prescrição de fertilizante potássico (K2O) em função do método de interpolação

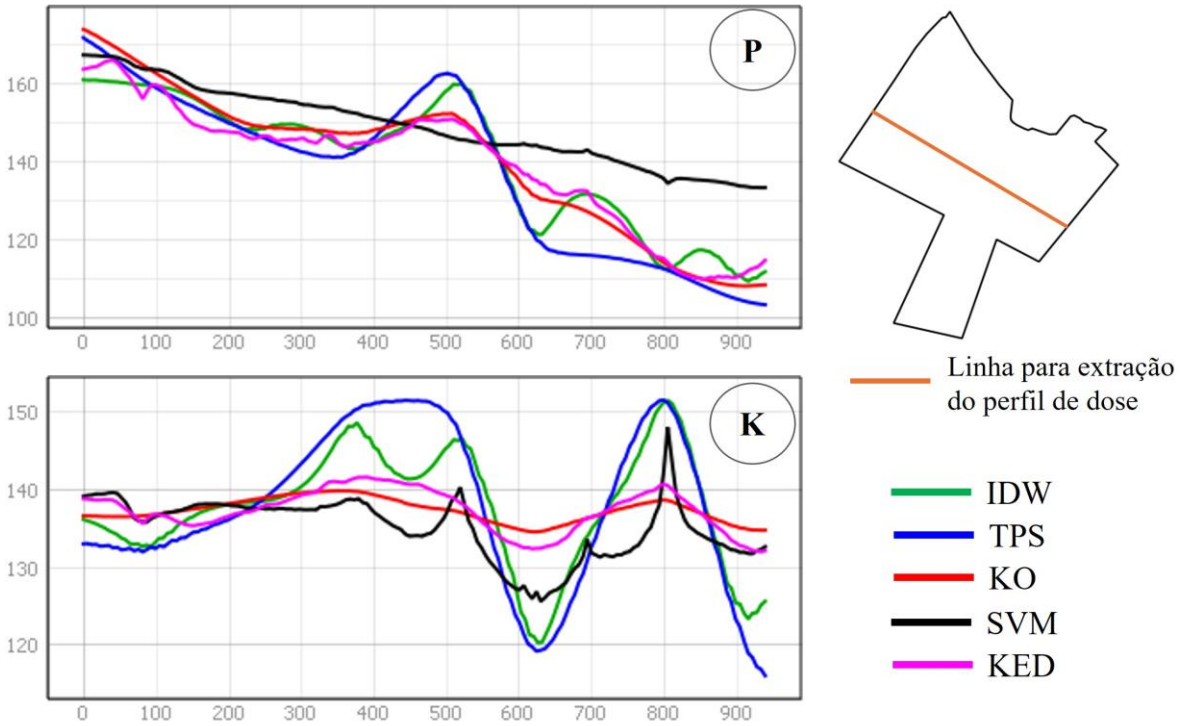


FIGURA 5. Doses dos fertilizantes fosfatado e potássico ao longo de um transecto estabelecido ao longo dos mapas de prescrição gerados pelos diferentes métodos de interpolação

Dentre os métodos determinísticos, o IDW tem a característica de apresentar os "olhos-de-boi", evidentes nos mapas já apresentados (Figuras 3 e 4). Esse método costuma ser empregado na agricultura de precisão em função da sua facilidade de implementação e simples configuração, já que, a grosso modo, possui como principal ajuste a potência (expoente) utilizada; nesse caso, o mais usual é utilizar a distância elevada ao quadrado, embora outras potências sejam aplicáveis e possam entregar melhores resultados, dependendo do conjunto de dados disponível. Já no caso dos *splines*, há uma infinidade de algoritmos e ajustes; neste trabalho utilizamos o *Thin Plate Spline* (TPS), o qual é um método simples e que tem como principal ajuste a "*regularização"*, a qual indica o nível de suavização que o algoritmo deverá implementar (neste trabalho, utilizamos o valor mínimo, ou seja, manter o máximo possível os valores originais nas coordenadas do ponto amostral). Nos mapas das Figuras 3 e 4 é possível notar que o TPS gera regiões de doses mais contínuas, assim como observado no transecto da Figura 5. Em termos de correlação com os valores de P e K nos pontos de validação, o TPS esteve entre os mais correlacionados (Tabela 2) e, quando avaliamos a classe de disponibilidade do nutriente no solo pelo índice Kappa, ele teve destaque, ou seja, foi o método que apresentou maior concordância entre as classes (baixo, médio, alto e muito alto) dos valores preditos e observados (Figura 7), o que resulta em maior parte da área dentro da mesma classe de recomendação de fertilizante. No entanto, apesar dos bons resultados apresentados, praticamente não há literatura sobre o uso de *splines* na agricultura de precisão, sendo uma demanda marcante para novas pesquisas, tanto em termos dos algoritmos mais indicados quanto das configurações a serem definidas ou otimizadas em função do tipo de dado disponível.

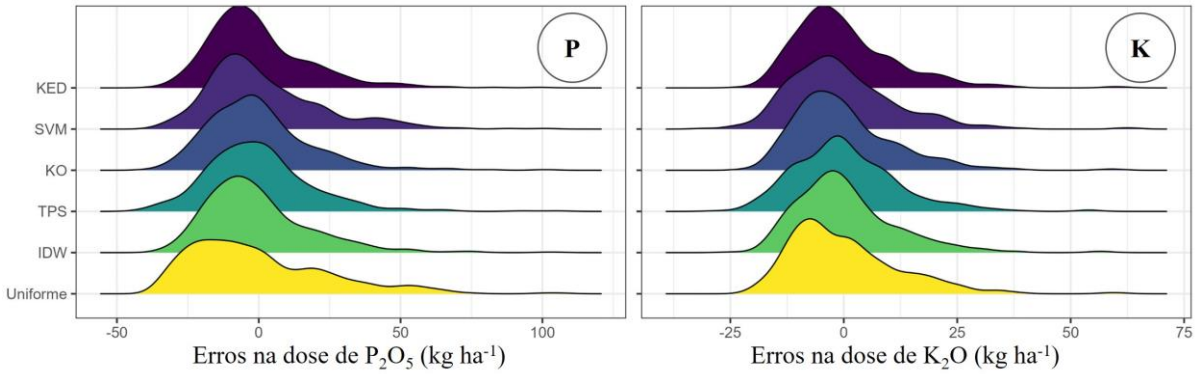


FIGURA 6. Distribuição dos erros de dose calculadas para os pontos de validação em função do método de interpolação e de uma única dose prescrita para a área toda.

Já com relação aos métodos multivariados utilizados (SVM e KED), não obtivemos bons resultados. Porém, isso não quer dizer que essas abordagens não sejam interessantes para a criação dos mapas de prescrição de fertilizantes, mas sim que a escolha das variáveis auxiliares é fundamental, assim como demonstrado por Pusch et al. (2023). Aqui utilizamos apenas a informação de suscetibilidade magnética do solo, a qual apresenta alta relação com mineralogia e textura do solo (Peluco et al., 2013; Camargo et al., 2014). Contudo, em se tratando de variáveis químicas do solo, essa relação, tanto da SM quanto da textura, pode ser baixa com a disponibilidade de nutrientes e, nesse caso, o método multivariado não entregará resultados satisfatórios. Goovaerts e Kerry (2010) e Kerry et al (2024) afirmaram que correlações da ordem de 0,5 entre variável principal e auxiliar já seriam suficientes para incrementar os mapeamentos realizados a partir de amostragem esparsa. Contudo, mesmo para o caso do P, onde encontramos correlação com SM de -0,40 (p = 0,013), esse ganho preditivo não foi observado (Tabela 2). Assim, esse valor limite de correlação não é estanque e deve ser avaliado caso a caso, corroborando o que também foi encontrado por Pusch et al (2021). O que precisa ser realizado no caso de utilização desse tipo de método, é a exploração preliminar das correlações entre as variáveis, buscando utilizar uma ou mais variáveis auxiliares que tenham relação com a variável que se quer mapear. Covariáveis de planta, solo, topografia e até mesmo de manejo podem apresentar relação com a distribuição espacial das propriedades químicas do solo e, portanto, o conjunto de dados precisa ser amplamente explorado em cada situação específica.

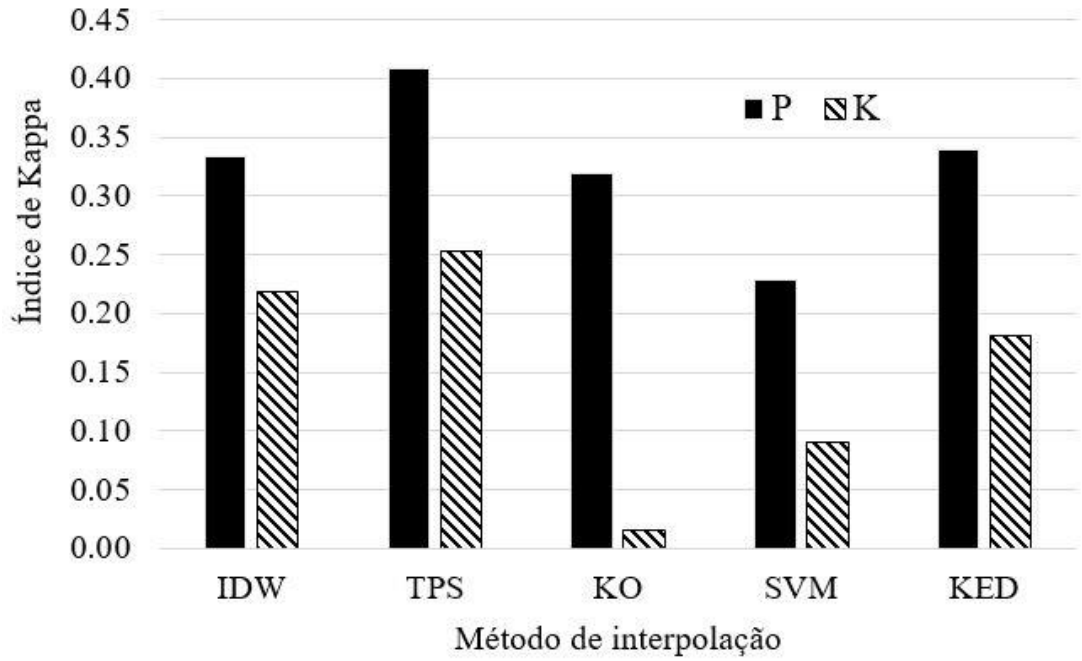


FIGURA 7. Concordância das classes de disponibilidade de P e K no solo em função do método de interpolação, medida pelo índice de Kappa nos pontos de validação

CONCLUSÃO

No caso de baixa dependência espacial das propriedades do solo em estudo, a krigagem ordinária suaviza demasiadamente as predições, o que tende a ocorrer com frequência quando empregado uma grade esparsa de amostragem. Desse modo, embora esse método seja amplamente defendido como o mais indicado para a realização de interpolação geoespacial, pode não ser a melhor escolha para a criação dos mapas de prescrição de fertilizantes em doses variadas.

Os métodos multivariados usados neste estudo (SVM e KED), embora tenham grande potencial, não apresentaram bom desempenho. Isso porque seu resultado é dependente da relação da propriedade que se quer mapear com a variável (ou variáveis) auxiliar adotada. Assim, a seleção das variáveis auxiliares deve ser explorada para cada situação; caso se encontre altas correlações, esses métodos poderiam ser empregados.

O método de *spline* utilizado neste trabalho, *Thin Plate Spline* - TPS, foi o que mais honrou as classes de disponibilidade dos nutrientes no solo. Além disso, também apresentou mapas de prescrição com alta amplitude de doses e manchas mais bem definidas. Isso mostra que os *splines* podem ser boa opção para a criação dos mapas de prescrição de fertilizantes. Porém, há diversos algoritmos e ajustes possíveis, demandando mais estudos para definição de diretrizes para uso em dados da agricultura de precisão.

AGRADECIMENTOS

Agradecemos à AgroQuatro-S, em nome do Dr. Sergio Quassi de Castro, pela disponibilização da área de estudo e suporte à experimentação. Enaltecemos o apoio do CNPq com a Bolsa de Produtividade Nível-2 ao primeiro autor (n° 306867/2022-2) e à FAPESP pelo apoio financeiro à essa e outras pesquisas, processo n° 2022/03160-8. Também agradecemos à FAPESP pela concessão de bolsa ao segundo autor, processo n° 2023/02592-4.

REFERÊNCIAS

AMARAL, L. R.; JUSTINA, D. D. Spatial dependence degree and sampling neighborhood influence on interpolation process for fertilizer prescription maps. **Engenharia Agricola**, v. 39, p. 85-95, 2019.

CAMARGO, L.A.; MARQUES JÚNIOS, J.; PEREIRA, G.T.; BAHIA, A.S.R.S. Clay mineralogy and magnetic susceptibility of Oxisols in geomorphic surfaces. **Scientia Agricola**, v.71, n.3, p.244-256, 2014.

CANTARELLA, H.; QUAGGIO, J. A.; MATTOS JUNIOR, D.; BOARETTO, R. M.; RAIJ, B. V. (ed.). **Boletim 100**: Recomendações de adubação e calagem para o estado de São Paulo. Campinas: Instituto Agronômico, 2022. 489 p.

CHERUBIN, M.R. *et al.* Eficiência de malhas amostrais utilizadas na caracterização da variabilidade espacial de fósforo e potássio. **Ciência Rural**, v. 44, n. 3, p. 425-432, 2014.

GEBBERS, R.; ADAMCHUK, V. I. Precision Agriculture and Food Security. **Science**, v. 327, p. 828-831, 2010.

GOOVAERTS, P.; KERRY, R. Using ancillary data to improve prediction of soil and crop attributes in precision agriculture. In: Oliver M. **Geostatistical Applications for Precision Agriculture**. Reino Unido: Springer, p. 167-194, 2010.

KERRY, R.; INGRAM, B.; OLIVER, M.; FROGBROOK, Z. Soil sampling and sensed ancillary data requirements for soil mapping in precision agriculture II: contour mapping of soil properties with sensed z?score data for comparison with management zone averages. **Precision Agriculture**, on-line, 2024.

LI, J.; HEAP, A.D. A review of comparative studies of spatial interpolation methods in environmental sciences: performance and impact factors. **Ecological Informatics**, v. 6, p. 228-241, 2011.

MOLIN, J.P. Agricultura de Precisão: números do mercado brasileiro. Boletim Técnico 03, Laboratório de Agricultura de Precisão, ESALQ/USP, 2017. Disponível em: < https://www.agriculturadeprecisao.org.br/boletim-tecnico-03-agricultura-de-precisao-numeros-do-mercado-brasileiro>. Acesso em: 04 de abril de 2024.

NANNI, M.R. *et al.* Optimum size in grid soil sampling for variable rate application in site-specific management. **Scientia Agricola**, v. 68, n. 3, p. 386-392, 2011.

OLIVER, M.A. **Geostatistical Applications for Precision Agriculture**. Reino Unido: Springer, 2010. 331 p.

PELUCO, R.F.; MARQUES JÚNIOR, J.; SIQUEIRA, D.S.; CORTEZ, L.A.; PEREIRA, G.T. Magnetic susceptibility in the prediction of soil attributes in two sugarcane harvesting management systems. **Engenharia Agrícola**, v.33, n.6, p.1134-1143, 2013.

PEREIRA, G.W.; VALENTE, D.S.M.; DE QUEIROZ, D.M. et al. Soil mapping for precision agriculture using support vector machines combined with inverse distance weighting. **Precision Agriculture**, v. 23, p. 1189-1204, 2022.

PUSCH, M.; OLIVEIRA, A.L.G.; FONTENELLI, J.V.; AMARAL, L.R. Soil properties mapping using proximal and remote sensing as covariate. **Engenharia Agricola**, v. 41, p. 634-642, 2021.

PUSCH, M.; SAMUEL-ROSA, A.; OLIVEIRA, A.L.G.; MAGALHAES, P.S.G.; AMARAL, L.R. Improving soil property maps for precision agriculture in the presence of outliers using covariates. **Precision Agriculture**, v. 23, p. 1575-1603, 2022.

PUSCH, M.; SAMUEL-ROSA, A.; MAGALHÃES, P.S.G.; AMARAL, L.R. Covariates in sample planning optimization for digital soil fertility mapping in agricultural areas. **Geoderma**, v. 429, 2023.

SANTOS, E.L.E.; SEIDEL, E.J.; PAZINI, J.B.; OLIVEIRA, M.S.; APPEL NETO, E.; BARBOSA, I.C. Some aspects about the spatial dependence index for variability of soil attributes. **Ciência Rural**, v.48, n. 6, e20170710, 2018.

SOARES, A. Geoestatística para as ciências da terra e do ambiente. Lisboa: IFT Press, 2014. 214 p.

VA?ÁT, R.; HEUVELINK, G.B.M.; BOR?VKA, L. Sampling design optimization for multivariate soil mapping. **Geoderma**, v. 155, p. 147-153, 2010.

VARIABILIDADE DE INDICADORES DE QUALIDADE NA COLHEITA MECANIZADA DE SORGO

KRISTHIAN BENDER JAEGER [1]; ROUVERSON PEREIRA DA SILVA [2]; VINÍCIUS DOS SANTOS CARREIRA [3]; BRENO DOS SANTOS SILVA [4]

[1]Estudantes. Via de Acesso Prof. Paulo Donato Castellane, km 5. UNIVERSIDADE ESTADUAL PAULISTA - CAMPUS DE JABOTICABAL; [2]Professor. Via de Acesso Prof. Paulo Donato Castellane, km 5. UNIVERSIDADE ESTADUAL PAULISTA - CAMPUS DE JABOTICABAL; [3]Doutorando. Via de Acesso Prof. Paulo Donato Castellane, km 5. UNIVERSIDADE ESTADUAL PAULISTA - CAMPUS DE JABOTICABAL; [4]Mestrando. Via de Acesso Prof. Paulo Donato Castellane, km 5. UNIVERSIDADE ESTADUAL PAULISTA - CAMPUS DE JABOTICABAL

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Apesar do avanço nas tecnologias utilizadas na agricultura, as perdas que ocorrem no processo de colheita mecanizada ainda são um tópico que requer atenção. Neste trabalho objetivou-se avaliar o efeito de três velocidades de deslocamento da colhedora nas perdas na colheita mecanizada de sorgo, utilizando o controle estatístico de processo. O trabalho foi realizado em uma propriedade do município de Maracaí - SP, em setembro de 2023. Para contabilizar as perdas, foi utilizada uma armação de 1 m^2, que foi posicionada no solo após a colheita, nos pontos amostrais, transversalmente ao sentido de deslocamento da colhedora. Os dados foram analisados por meio do Controle Estatístico de Processos, utilizando como indicadores de qualidade altura de inserção da primeira panícula, altura de plantas, fluxo de alimentação, biomassa, perdas, produtividade e NDVI. O processo foi considerado estável para maioria das variáveis analisadas. Os indicadores de qualidade altura de inserção da primeira panícula, fluxo de alimentação, perdas e NDVI apresentaram maiores variabilidades para IVm = 0,93.

PALAVRAS-CHAVE: controle estatístico; cartas de controle; índice de velocidade do molinete

ABSTRACT

Despite advances in agricultural technologies, losses occurring in the process of mechanized harvesting remain a topic that requires attention. This study aimed to evaluate the effect of three speeds of harvester displacement on losses in the mechanized harvesting of sorghum, using Statistical Process Control. The study was conducted on a farm in the municipality of Maracaí - SP, Brazil, in September 2023. To quantify the losses, a frame of 1 m^2 was used, which was positioned on the soil after harvesting, at sampling points, transversely to the direction of harvester displacement. The data were analyzed using Statistical Process Control, utilizing quality indicators such as insertion height of the first panicle, plant height, feeding flow, biomass, losses, yield, and NDVI. The process was considered stable for most of the variables analyzed. Quality indicators such as insertion height of the first panicle, feeding flow, losses, and NDVI showed greater variability for VIm = 0.93.

KEYWORDS: ;

INTRODUÇÃO

O sorgo (*Sorghum bicolor L. Moench*) está entre os cereais mais plantados no mundo, destacando-se pela sua maior tolerância ao estresse hídrico quando comparado a outras culturas. A realização da colheita mecanizada leva à ocorrência de perdas durante o processo. Lazzarotto et al. (2019), ao avaliarem as perdas de grãos de sorgo granífero na colheita mecanizada de sorgo, não encontram diferença para as perdas em velocidades de deslocamento da colhedora entre 3 e 9 km $h^{?1}$.

Diversos autores têm utilizado ferramentas do Controle Estatístico de Processos (CEP) para estudar a colheita mecanizada de algumas culturas, porém, não são encontrados trabalhos que envolvam o uso do CEP na colheita de sorgo. Menezes et al. (2018) avaliaram a qualidade da colheita mecanizada de soja com diferentes plataformas de corte e velocidades de deslocamento e constataram melhor qualidade no processo de colheita com a plataforma de esteira, com pouca influência da velocidade de deslocamento, além de que os níveis de perdas foram acima do limite aceitável, indicando necessidade de melhoria no processo. Lima et al. (2017), buscaram determinar e caracterizar as perdas quantitativas e as características operacionais de uma colhedora de fluxo axial em duas velocidades (5 e 7 km h^{-1}) e observaram que as características operacionais mantiveram-se estáveis para ambas as velocidades, já as perdas aumentaram com a maior velocidade, contudo mantiveram-se em níveis aceitáveis.

O CEP tem sido bastante utilizado para avaliar o processo de colheita de varias culturas, porém, para a cultura do sorgo não são encontradas pesquisas sobre este tema.

OBJETIVOS

Partindo da suposição que difentes regulagens da colhedora podem proporcionar alterações na qualidade da colheita de sorgo, objetivou-se neste trabalho avaliar a variabildiade das perdas na colheita mecanizada de sorgo e de outros indicadores de qualidade sob três índices de velocidade do molinete, utilizando o controle estatístico de processo.

MATERIAL E MÉTODOS

O trabalho foi realizado na Fazenda Jaeger localizada nas coordenadas geográficas a 22°40,45"S e 50°49,22"O, em Maracaí, SP. O clima predominante segundo a classificação de Köeppen é o cfa, subtropical úmido. O experimento foi realizado em um talhão de 15 hectares, semeado o sorgo granífero da Nussed, cultivar Nugreed 430, com espaçamento de semeadura de 50 cm entre linhas e 12 plantas m^{-1}, totalizando uma população de 240.000 plantas $ha^{?1}$.

A colheita da área experimental foi realizada no dia 1 de setembro de 2023 por uma colhedora da marca New Holland, modelo TC57 Hydro, ano 2007, com 125,8 kW (170 cv) de potência no motor, sistema de trilha tangencial, acoplada com uma plataforma para a colheita de cereais também da marca New Holland, com largura de corte de 5,80 m, mantida com as mesmas regulagens para todos os tratamentos (900 rpm no cilindro, 800 rpm no ventilador e o côncavo na posição 2, em uma escala de 1 a 14). A altura de corte média foi de 40 cm.

O delineamento utilizado obedeceu às premissas do Controle Estatístico de Processos, com as amostras coletadas ao longo do tempo. Para cada variável analisada, foram coletadas 15 amostras, espaçadas entre si por 15 m. Os tratamentos utilizados foram definidos por três velocidades de deslocamento da colhedora (3,0; 4,5 e 6,0 km h^{-1}), que corresponderam aos índices de velocidade do molinete (IVm) de 1,88; 1,25 e 0,93, respectivamente.

Com auxílio de uma trena foram avaliadas a altura de inserção da primeira panícula e altura da planta. Para determinação da biomassa da parte aérea utilizou-se uma armação de 0,5 m^2, dentro da qual foram coletadas, a partir de 40 cm do solo, todas as plantas encontradas. As amostras tiveram sua massa determinada em uma balança com precisão de 1 g. De cada uma das amostras foram retiradas todas as panículas, que foram debulhadas e pesadas para determinação da produtividade. O fluxo de alimentação da colhedora foi determinado de acordo com a equação 1.

? = (L.v.BM)/10.000

Em que,

?: fluxo de alimentação kg s^{-1}; L: largura da plataforma, m; v: velocidade da colhedora m s^{-1}; BM: biomassa kg ha^{-1}.

Para a determinação das perdas na colheita foi utilizada uma armação de 1 m^2, posicionada no solo após a colheita, nos pontos amostrais, transversalmente ao sentido de deslocamento da colhedora e, dentro dessa armação foram coletados os grãos soltos e as panículas sobre o solo.

Foi calculado o NDVI, obtido por meio de imagens de satélites da plataforma PlanetScope CubeSat, com resolução de 3-5 m. Os satélites da PlanetScope possuem quatro bandas espectrais, sendo três no visível, Azul-Blue (455-515 nm), Verde-Green (500-590), vermelho-Red (590-670 nm) e uma no infravermelho próximo-NIR (780-860 nm) (PLANET TEAM, 2023). As imagens foram processadas no software QGIS 3.22.6 (Boston, MA, EUA).

Para análise dos dados foram utilizadas cartas de controle individuais, sendo os limites de controle iguais à média ± o desvio-padrão.

RESULTADOS E DISCUSSÃO

O NDVI apresentou comportamento esperado na área do estudo (destacada na FIGURA 1), com variabilidade espacial muito pequena, embora, quando considerada todo o talhão esta variabilidade tenha sido maior. A homogeneidade espacial da vegetação na área do estudo pode ser associada à maturação da cultura, uma vez que a imagem corresponde ao fim do estádio vegetativo da planta, momento no qual as panículas estão iniciando a maturação.

Analisando as cartas de controle para altura de inserção da primeira panícula (AIPP) e altura de plantas (AP) (FIGURA 2), constata-se que o processo manteve-se estável para todos os tratamentos analisados, exceto para o tratamento 3 (v=6,0 km h^{-1}) na variável AIPP (FIGURA 2.a). As menores variabilidades foram encontradas no tratamento 2 (v=4,5 km h^{-1}), tanto para AIPP quanto para AP, indicando que neste tratamento as plantas encontravam-se mais uniformes. Essa menor variabilidade na área onde se encontrava o tratamento 2 é decorrente de fatores não relacionados com a velocidade de deslocamento, tais como solo, desuniformidade na distribuição dos restos culturais, além disso a parcela com tratamento 2 tem as menores médias de AIPP e AP (96,1 cm e 114,6 cm, respectivamente).

Já nas parcelas cuja velocidade foi de 3,0 km h^{-1}, as médias de AIPP e AP foram de 103,7 cm e 125,5 cm, respectivamente, enquanto na parcela do tratamento 3 (v= 6,0 km $h^{?1}$) estas médias foram de 107,0 cm (AIPP) e 127,8 cm (AP). Nota-se que a altura média das plantas, em todas as parcelas, foi menor que aquela prevista no manual técnico da empresa fornecedora (1,50 m). Isso pode ser atribuído à semeadura tardia (abril) e a falta de chuvas durante o desenvolvimento da cultura.

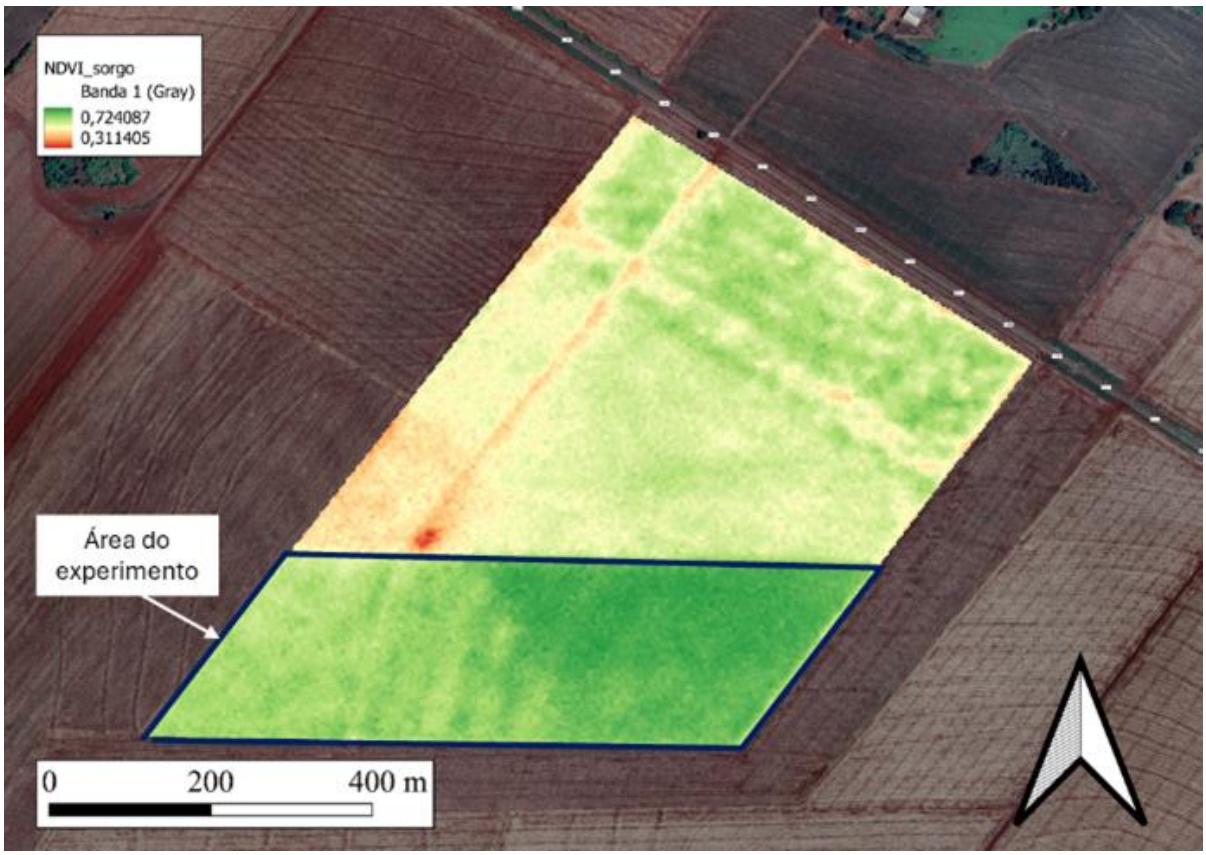


FIGURA 1. Mapa para visualização do NDVI na área de estudo.

FIGURA 1. Mapa para visualização do NDVI na área de estudo.

Para o fluxo de alimentação e biomassa (FIGURA 3) o processo manteve-se estável para todos os tratamentos utilizados. No fluxo de alimentação (FIGURA 3.a), nota-se que as médias foram aumentando conforme os tratamentos, o que já era esperado, pois, o fluxo de alimentação é diretamente proporcional à largura da plataforma, biomassa e velocidade, que aumentou de 3,0 para 6,0 km $h^{?1}$. Observando os valores de biomassa (FIGURA 3.b), contata-se que a biomassa diminuiu nos talhões nos quais foram utilizadas as maiores velocidades, entretanto, esta diminuição não foi suficiente para proporcionar a diminuição do fluxo de alimentação.

Analisando a carta de controle sobre as perdas na colheita, constata-se que o processo manteve-se estável apenas para o tratamento 1 (v = 3,0 km h^{-1}), enquanto nos tratamentos 2 (v = 4,5 km h^{-1}) e 3 (v = 6,0 km h^{-1}) as observações número 26 e 33 levaram à instabilidade do processo. Estes pontos, muito discrepantes em relação aos demais, em cada tratamento, representam a ocorrência de causas especiais nos processos, que neste caso podem ser atribuídas aos fatores mão de obra ou meio ambiente. Quanto ao fator mão de obra, pode ter ocorrido alteração na altura de corte nos dois pontos fora de controle, ocasionado a elevação do molinete e, consequentemente, elevando os valores das perdas. Já para o fator meio ambiente, a presença de javalis na área, provocando a formação de reboleiras com plantas acamadas, o que eleva os índices de perdas na colheita. Zerbato et al. (2013), ao trabalharem com perdas na colheita de milho, também constataram instabilidade no processo para o indicador de qualidade perdas na colheita, e apontaram que as causas decorrem de regulagem inadequada ou mau funcionamento da máquina, o que aumenta a quantidade de perdas totais.

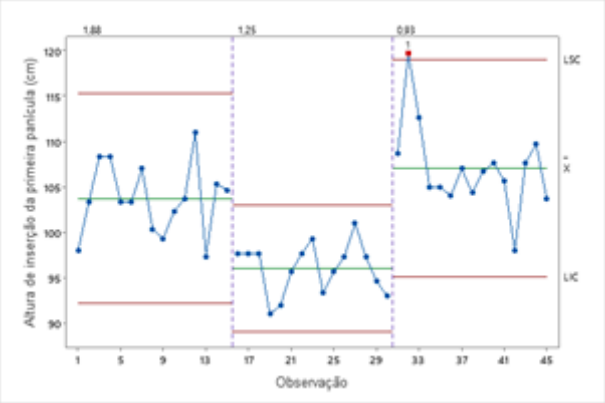


Figura 2.a

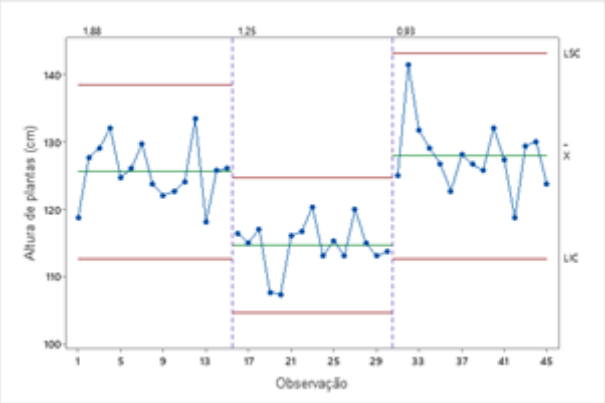


Figura 2.b

FIGURA 2. Cartas de controle individuais para: a) Altura de inserção da primeira panícula; b) Altura de plantas.

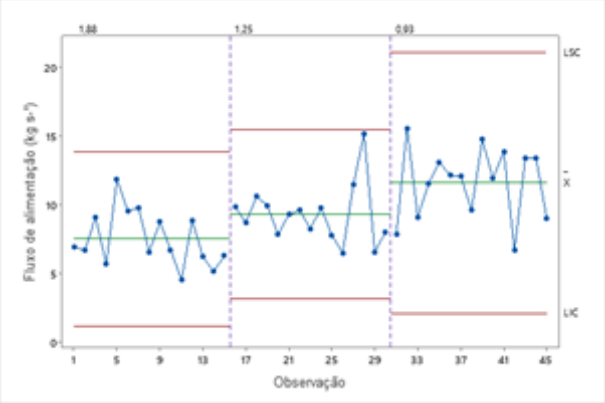


Figura 3.a

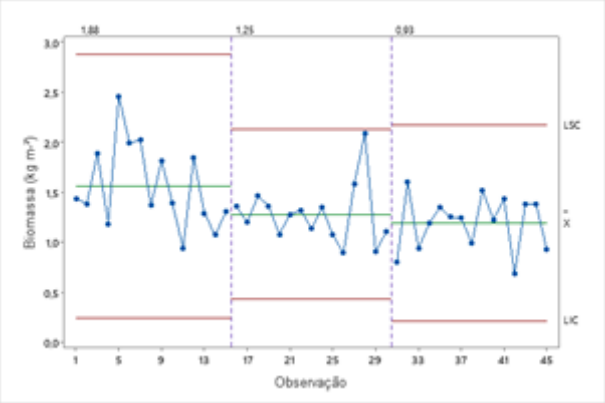


Figura 3.b

FIGURA 3. Cartas de controle individuais para: a) Fluxo de alimentação; b) Biomassa.

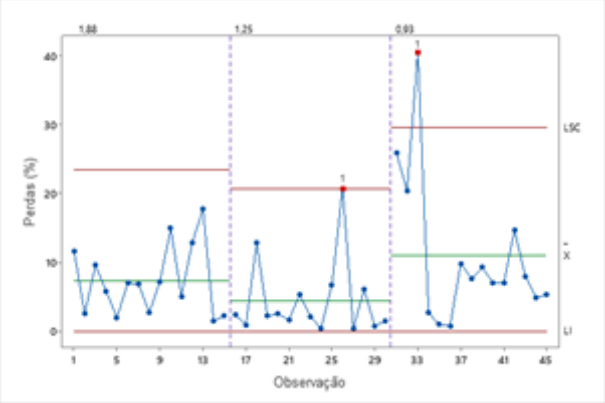


Figura 4.a

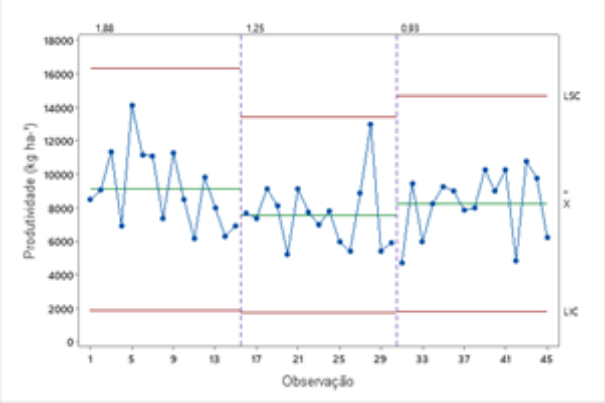


Figura 4.b

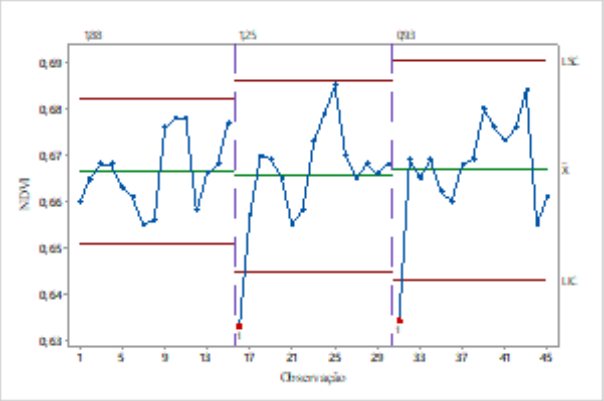


Figura 4.c

FIGURA 4. Cartas de controle individuais para: a) Perdas; b) Produtividade; c) NDVI.

CONCLUSÃO

O processo foi estável para a maioria dos indicadores de qualidade analisados, exceto para altura de inserção da primeira panícula (IVm = 0,93), perdas e NDVI (IVm = 1,25 e 0,93). As maiores variabilidades para os indicadores de qualidade altura de inserção da primeira panícula, fluxo de alimentação, perdas e NDVI foram observadas no tratamento 3 (IVm = 0,93), e no tratamento 1 (IVm = 1,88) para altura de plantas, biomassa e produtividade.

REFERÊNCIAS

Andrade TG, Andrade JASD, Souza MO, Lopes JWB, Vieira PFDMJ (2022) Soybean yield prediction using remote sensing in southwestern Piauí state, Brazil. Revista Caatinga, 35, 105-116.

Lazzarotto E, Neves E, Arruda E, Savelli RA (2019) Perdas quantitativas na colheita de sorgo granífero de segunda safra em função da velocidade da colhedora. ENCICLOPEDIA BIOSFERA, 16(29).

Menezes CB (2015) Sorghum grain: extend your second crop with safety. In:Portal Embrapa. www.embrapa.br/sorgo-granifero-estenda-sua-safrinha-com-seguranca. Accessed Dec 08, 2023.

Zerbato, C, Cavichioli, FA, Raveli MB, Marrafon M, Silva, RP (2013) Controle estatístico de processo aplicado à colheita mecanizada de milho. Revista Engenharia na Agricultura-REVENG, 21(3), 261-270.

GERAÇÃO DE DADOS SINTÉTICOS PARA USO EM VISÃO COMPUTACIONAL E PULVERIZAÇÃO AGRÍCOLA

JOEL CARNEIRO DA CUNHA JUNIOR [1]; AMÉLIA LAISY DO NASCIMENTO [2]; JOÃO MARCELO DOS SANTOS SOARES [1]; JOSELY CARLA FERREIRA MENDES [1]; VICTOR BATISTA RODRIGUES [1]
[1]Discente. Rua Dom Manuel de Medeiros, s/n - Dois Irmãos, Recife - PE, 52171-900. UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO; [2]Docente. Rua Dom Manuel de Medeiros, s/n - Dois Irmãos, Recife - PE, 52171-900. UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
Em pulverização, é comum o uso de etiquetas hidrosensíveis espalhados por uma cultura agrícola para avaliar a qualidade da aplicação. Em seguida são feitas imagens das etiquetas manchadas e tais imagens passam por processos de visão computacional para determinação de características das gotas. Para o uso de visão computacional, são necessários dados para o treinamento e teste dos modelos. No entanto, o custo de obtenção de dados pode ser inacessível a uma parcela da população. Assim, objetivou-se desenvolver um algoritmo para geração de dados sintéticos que simulam uma pulverização agrícola visando o seu uso em testes e aulas de visão computacional e/ou aplicação de defensivos. As simulações foram realizadas adotando pressões de trabalho do pulverizador em 100, 300 e 500 kPa, a temperatura em 20º, 30º e 40º C e a umidade relativa do ar em 40, 70 e 90%. No total, foram geradas 27 imagens de etiquetas hidrossensíveis manchadas com gotas de tamanhos variados resultantes das simulações da pulverização. O uso de dados sintéticos em estudos de visão computacional apresentaram grande potencial, sendo os dados gerados capazes de emular ocorrências comuns existentes em etiquetas hidrossensíveis usadas em pulverizações reais.

PALAVRAS-CHAVE: aplicação de defensivos agrícolas; processamento digital de imagens; agrotóxicos

ABSTRACT
In spraying, it is common to use water-sensitive labels spread across an agricultural crop to assess the quality of the application. Images of the stained labels are then taken and these images go through computer vision processes to determine the characteristics of the drops. To use computer vision, data is needed for training and testing models. However, the cost of obtaining data may be inaccessible to a portion of the population. Thus, the objective was to develop an algorithm for generating synthetic data that simulates agricultural spraying with a view to its use in computer vision tests and classes and/or pesticide application. The simulations were carried out by adopting the sprayer working pressure at 100, 300 and 500 kPa, the temperature at 20º, 30º and 40º C and the relative air humidity at 40, 70 and 90%. In total, 27 images of water-sensitive labels stained with drops of varying sizes resulting from spraying simulations were generated. The use of synthetic data in computer vision studies presented great potential, with the data generated capable of emulating common occurrences observed in water-sensitive labels used in real spraying

KEYWORDS: ;

INTRODUÇÃO

Para que o uso de defensivos agrícolas seja realizada de forma adequada, é necessária que ocorra uma avaliação da aplicação. Em pulverização, é comum o uso de pápeis hidrosensíveis espalhados pela cultura, os quais ficam manchados nas posições em que gotas do líquido tocam a etiqueta. Em seguida

são feitas imagens das etiquetas manchadas e tais imagens passam por processos de visão computacional para determinação de características das gotas da pulverização.

Ferramentas e métodos de visão computacional se tornam cada vez mais populares nas mais diversas atividades da sociedade moderna. O seu uso depende de modelagem que por sua vez necessita de dados para o treinamento e teste dos modelos. No entanto, a obtenção de dados apresenta desafios como os custos envolvidos e a possível presença de viés (BORKMAN et al., 2021).

A atividade de aplicação de defensivos agrícolas pode causar impactos ambientais, além de estar diretamente relacionada à questões de saúde de seres-humanos e demais animais. Tal fato justifica o pagamento das despesas necessárias para a avaliação de uma pulverização agrícola real. No entanto, o custo pode ser inacessível quando o interesse é aprender ou testar técnicas de visão computacional aplicadas à atividade de pulverização de defensivos agrícolas. Ao menos, esta é uma realidade enfrentada por alguns docentes em instituições educacionais brasileiras.

A simulação de dados torna possível treinar e testar modelos de forma controlável e customizável, evitando os desafios de coleta e anotação de dados do mundo real (BORKMAN et al., 2021). Outra vantagem é que a simulação de dados requer tempo de computação em vez de tempo humano (BORKMAN et al., 2021), além de não ser necessário o uso de material físico para a coleta das informações. Sendo assim, o objetivo deste trabalho foi desenvolver um algoritmo para geração de dados sintéticos que simulam uma pulverização agrícola. O algoritmo foi criado visando o seu uso em testes e aulas de visão computacional e/ou pulverização agrícola.

OBJETIVOS

Desenvolver um algoritmo para geração de dados sintéticos que simulam uma pulverização agrícola

MATERIAL E MÉTODOS

A metodologia seguida neste trabalho foi inspirada no processo habitual de avaliação de pulverizações. Esse processo é constituído de três etapas, o espalhamento de etiquetas no campo1, logo após é realizada a pulverização2, e em seguida captura-se imagens das etiquetas e analisa, por meio de processamento digital de imagens (PDI)3. Entretanto neste trabalho os tamanhos das gotas resultantes de uma pulverização foram simulados por meio das equações 1, 2 e 3 (MACIEL et al., 2016). As simulações foram realizadas variando, nas equações 1, 2, 4 e 5, a pressão de trabalho do pulverizador em 100, 300 e 500 kPa, a temperatura em 20º, 30º e 40º C e a umidade relativa do ar em 40, 70 e 90%. No total, foram geradas 27 imagens de etiquetas hidrossensíveis manchadas com gotas de tamanhos variados resultantes das simulações da pulverização. As simulações foram realizadas na linguagem de programação R versão 3.9 (2009).

$$VMD = DPVar \cdot 0,059658 + 279,146 - P \cdot 0,25302 \quad \text{Eq. (55)}$$

$$D_{v10} = 149,95 - DPVar \cdot 0,122669 - P \cdot 0,133629 + DPVar \cdot P \cdot 0,00035741 \quad \text{Eq. (56)}$$

$$D_{v90} = 511,298 + DPVar \cdot 1,37339 - P \cdot 0,485595 \quad \text{Eq. (57)}$$

em que: DPVar = déficit de pressão de vapor d'água; VMD = Diâmetro da mediana volumétrica, μm; D_{v10} = Diâmetro da gota correspondente a 10% do volume aplicado, μm; D_{v90} = Diâmetro da gota correspondente a 90% do volume aplicado, μm; P = Pressão de trabalho,kPa;

Após obtenção dos VMD, D_{v10} e D_{v90}, foram calculados os números de gotas por unidade de superfície (gotas?cm^{-2}) por meio das equações 4, 5 e 6. Para efeito de cálculo, foi considerado que o volume a ser pulverizado na simulação era de 10 L?ha^{-1}.

$$n_{VMD} = 1,9098 \cdot 10^7 \cdot Q/VMD^3 \quad \text{Eq. (58)}$$

$$n_{D_{v10}} = 1,9098 \cdot 10^7 \cdot Q/{D_{v10}}^3 \quad \text{Eq. (59)}$$

$$n_{D_{v90}} = 1,9098 \cdot 10^{7} \cdot Q / {D_{v90}}^{3}$$ Eq. (60)

em que: n_{VMD} = número de gotas cujo diâmetro corresponde ao VMD; n_{Dv10} = número de gotas cujo diâmetro corresponde ao D_{v10}; n_{Dv90} = número de gotas cujo diâmetro corresponde ao D_{v90}; Q = Volume aplicado, L?ha^{-1};

Com os diâmetros VMD, D_{v10}, D_{v90} e números de gotas por unidade de superfície n_{VMD}, n_{Dv10}, nD_{v90} foram plotados pontos azuis sobre um fundo amarelado. Tal fundo foi criado de uma forma que apresentasse um gradiente na coloração simulando uma superfície com diferente incidência de iluminação. Junto ao fundo amarelado da imagem também foram inseridos pequenos pontos com diferentes tons do gradiente amarelo para simular a textura da etiqueta hidrosenssível. A quantidade de pontos azuis plotados foi proporcional aos n_{VMD}, n_{Dv10}, nD_{v90} e os tamanhos dos pontos azuis foram proporcionais aos VMD, D_{v10}, D_{v90}. Dessa forma, foram criadas as imagens simuladas de etiquetas hidrossensíveis para cada condição proposta.

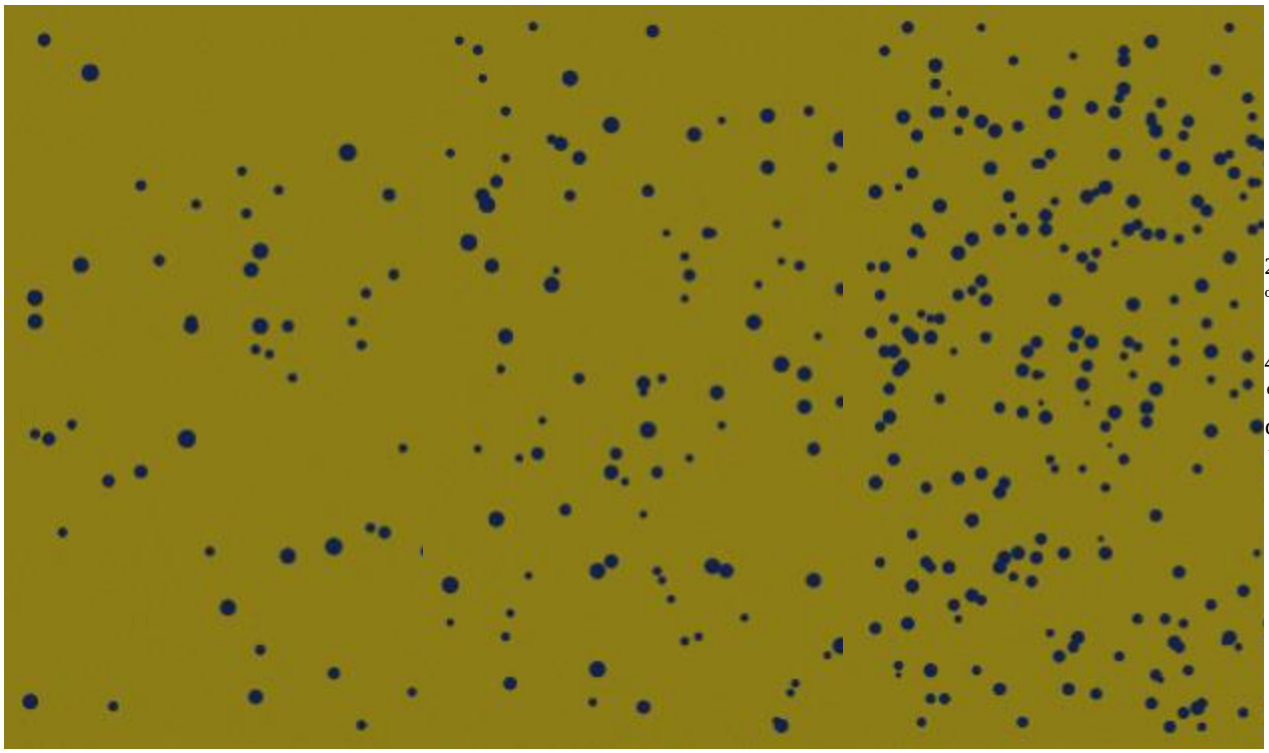
Com as etiquetas prontas, foi feito um processamento digital para que as imagens das etiquetas das condições de pulverização simuladas ficassem com aparência mais fiel e similares à uma imagem capturada em condições reais. Assim, nessa etapa, foram aplicados os filtros Noise (Ruído) e Blur (desfoque).

RESULTADOS E DISCUSSÃO

Os números de gotas por unidade de superfície n_{Dv10}, n_{Dv90} variou entre 75 a 332. Já o n_{VMD} variaram entre o mínimo de 12 até o máximo de 54 enquanto o n_{Dv90} ficou no intervalo de 2 a 10. É possível notar que os resultados das simulações seguiu perfeitamente a lógica de que quanto maior o tamanho da gota, menores são as suas quantidades sobre a superfície da etiqueta hidrossensível. Os tamanhos mínimo e máximo das gotas geradas nas simulações foi de 65,77µm e 518µm, respectivamente. Com todos esses dados gerados pelos cálculos foram plotadas 27 imagens (Tabela 1).

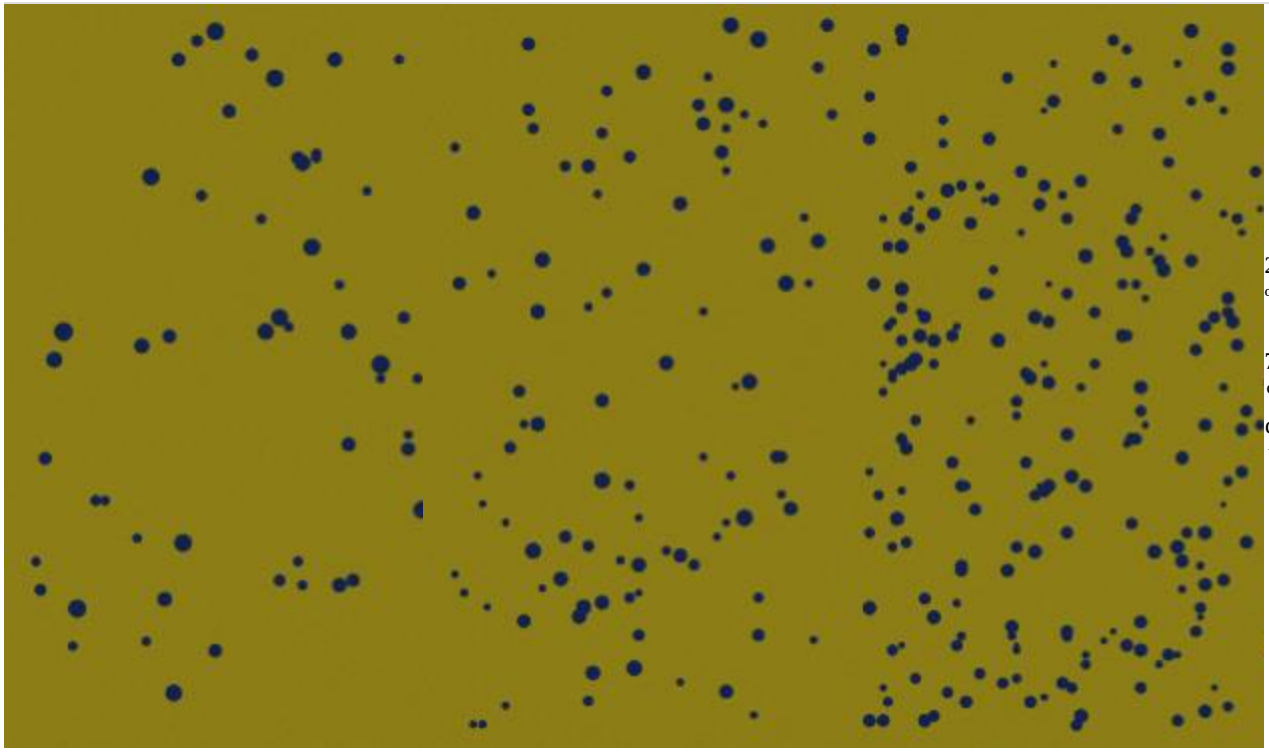
Tabela 1. Imagens das etiquetas hidrossensíveis simuladas para as condições de Pressão igual à 100, 300 e 500 KPa, Temperatura de 20, 30 2 40º C, e umidade relativa (UR) do ar igual à 40, 70 e 90%.

100 KPa	300 KPa	500 KPa



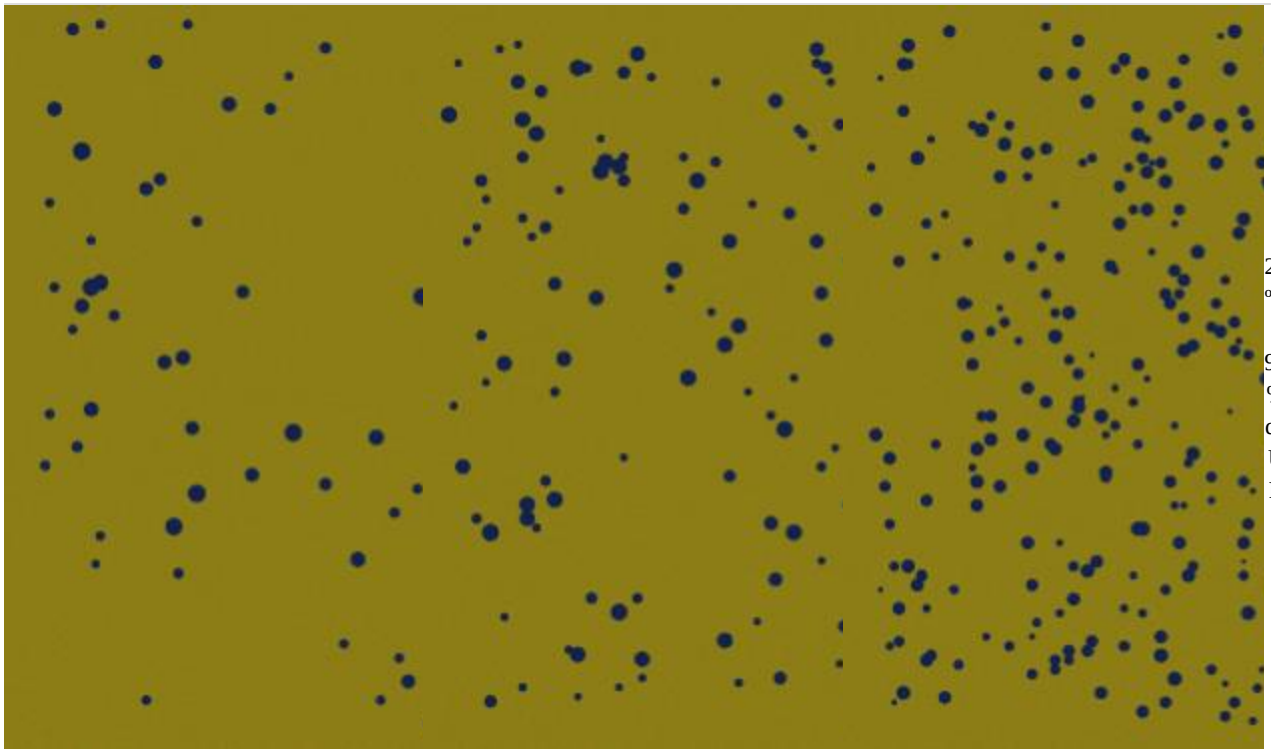
20 ºC e 40 % de UR

Image1 Image2 Image3



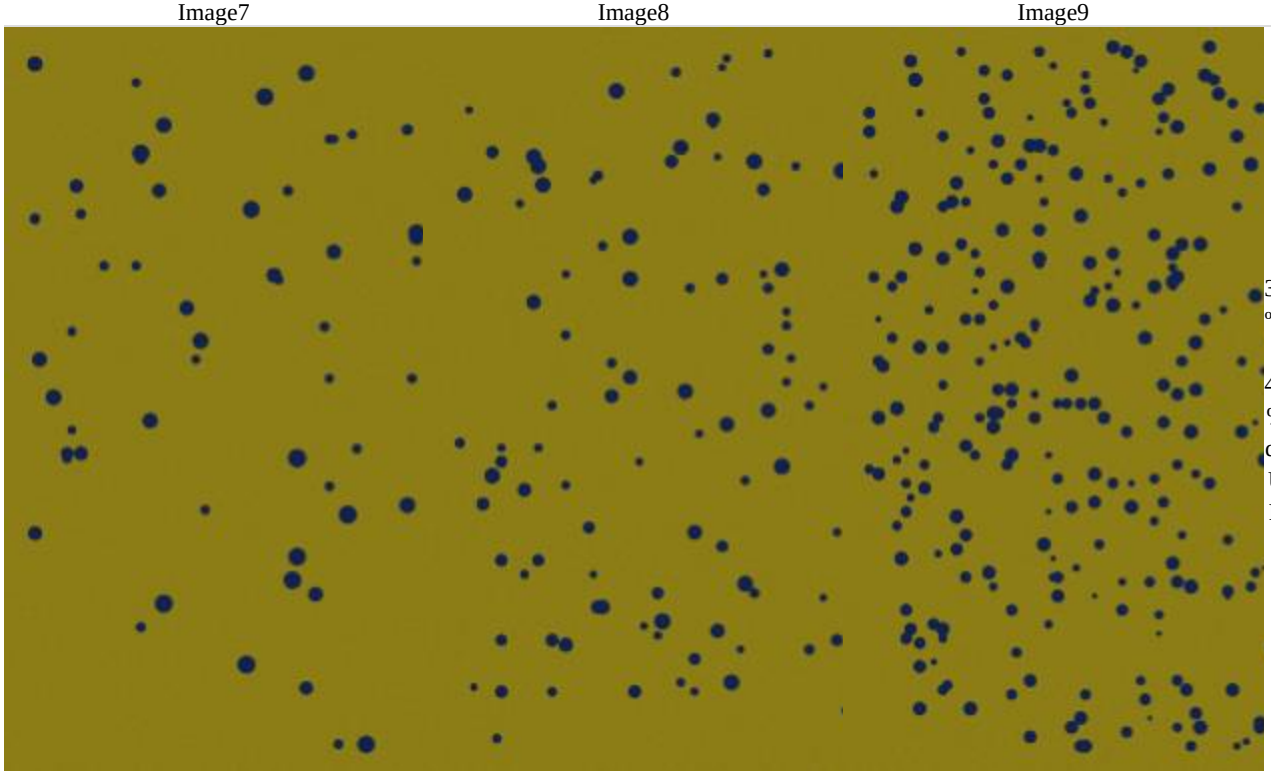
20 ºC e 70 % de UR

Image4 Image5 Image6



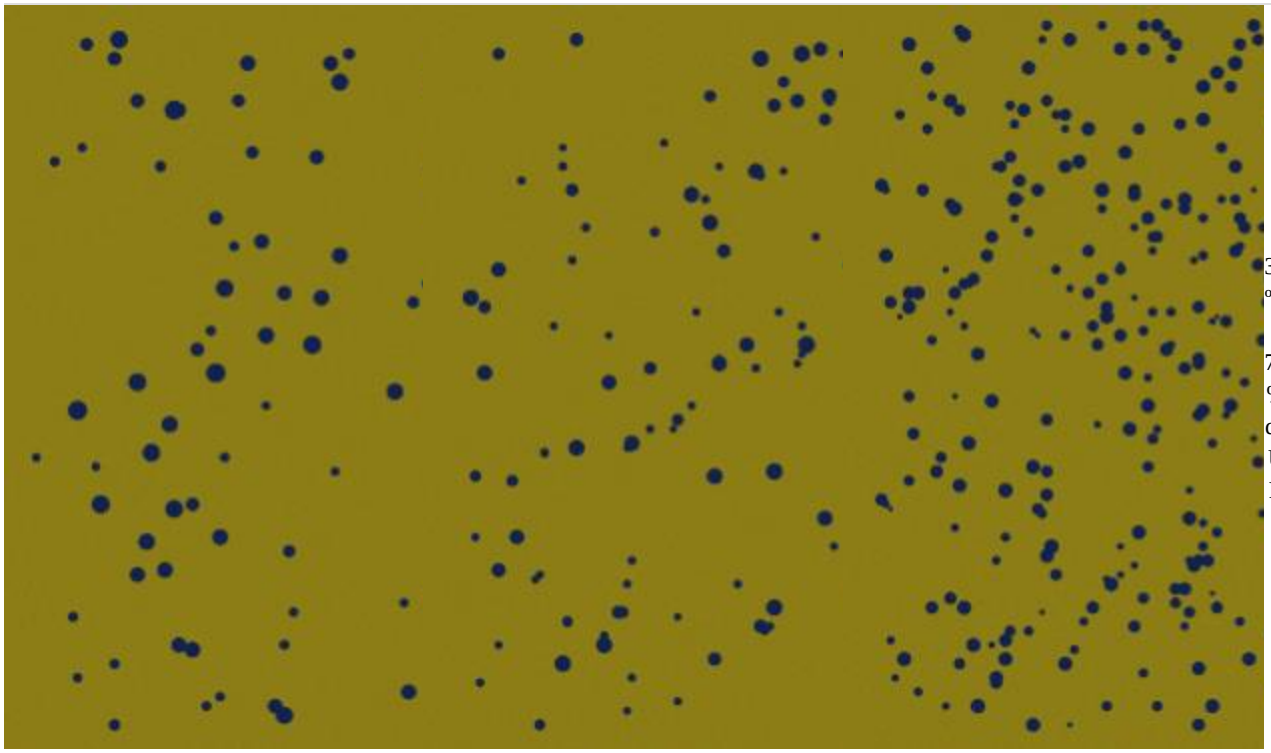
20 ºC e 90 % de UR

Image7 Image8 Image9



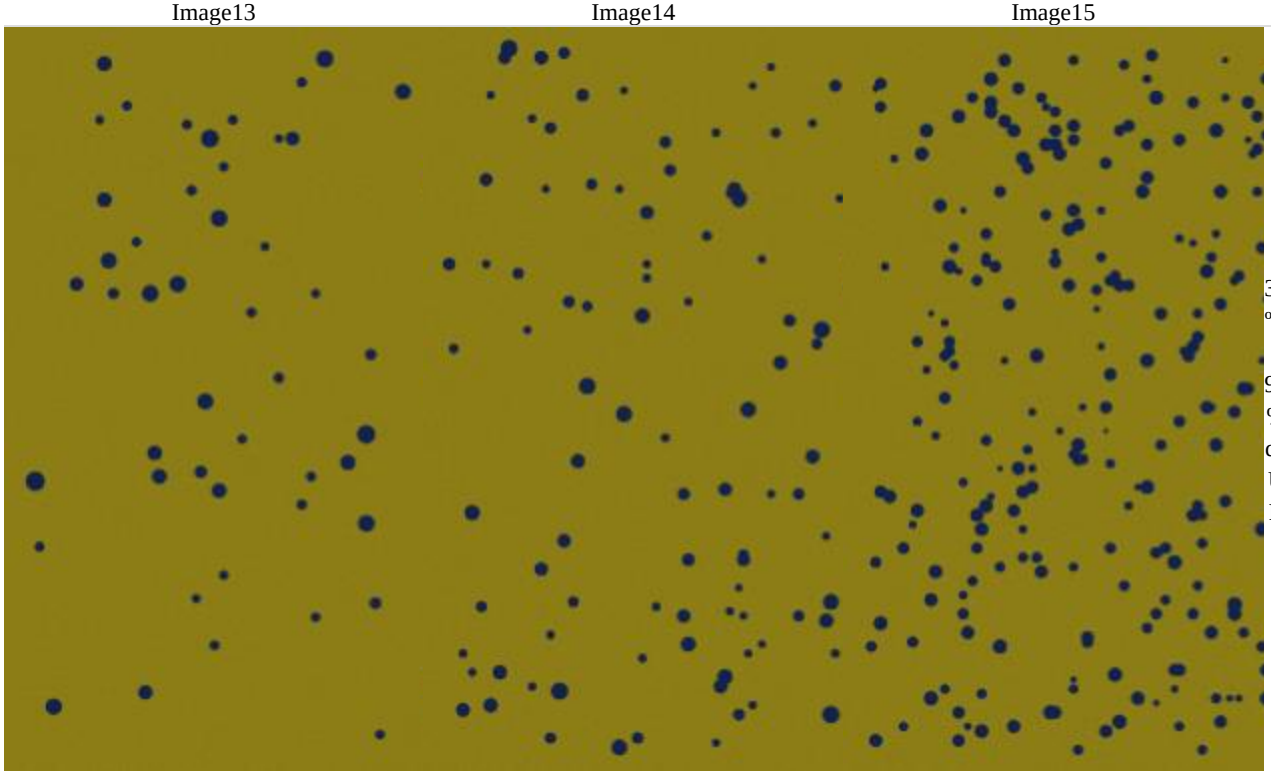
30 ºC e 40 % de UR

Image10 Image11 Image12



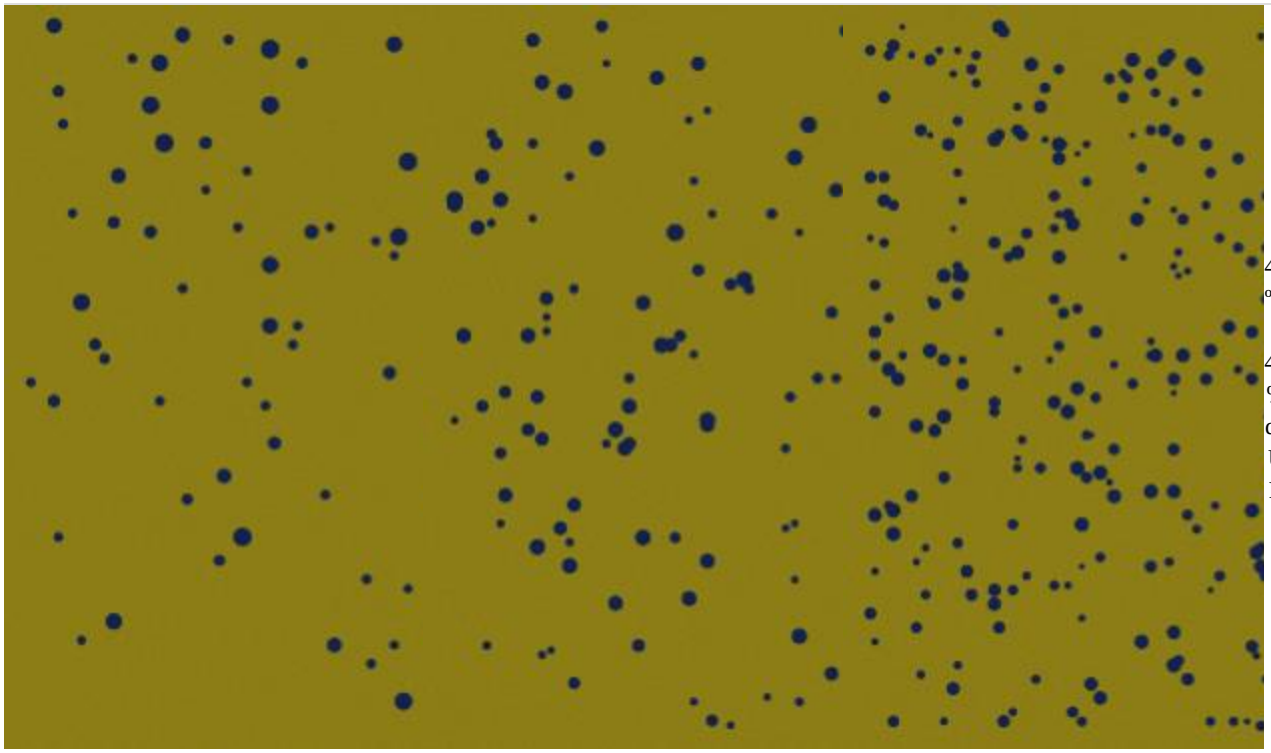
30 ºC e 70 % de UR

Image13 Image14 Image15



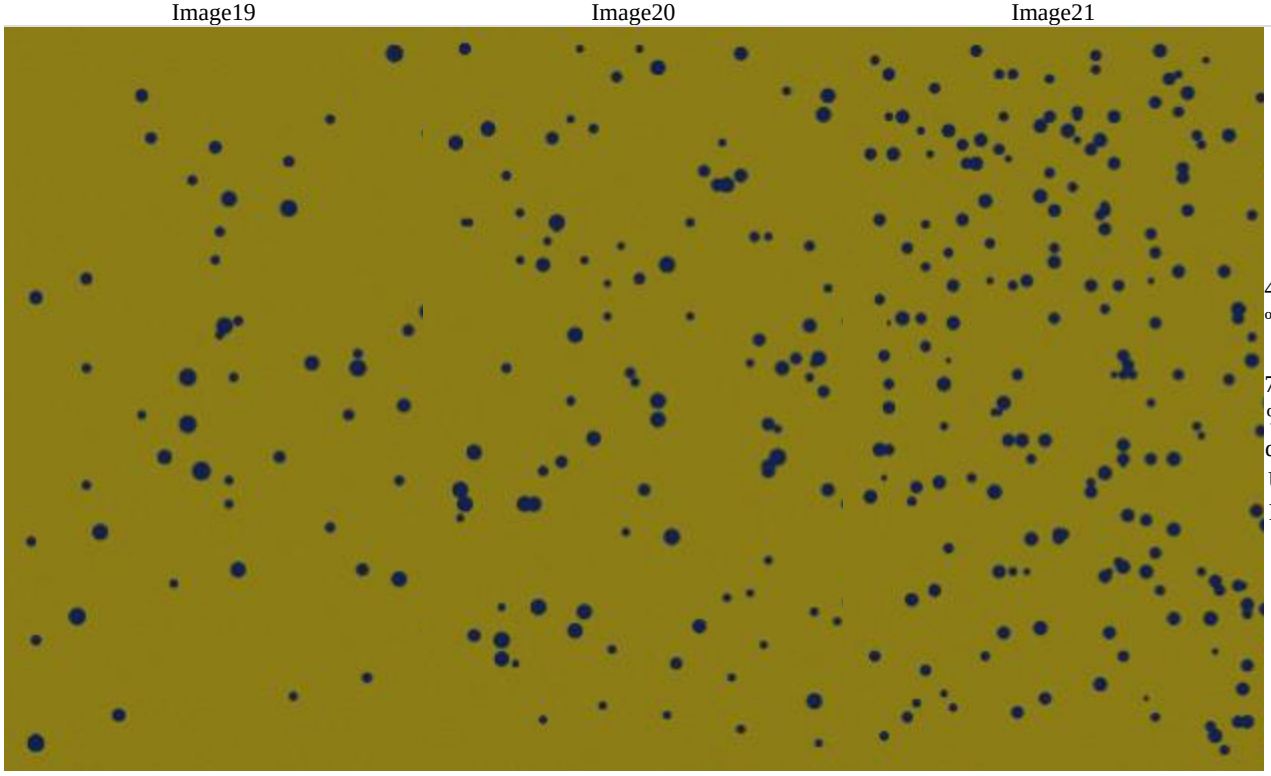
30 ºC e 90 % de UR

Image16 Image17 Image18



40 ºC e 40 % de UR

Image19 Image20 Image21



40 ºC e 70 % de UR

Image22 Image23 Image24

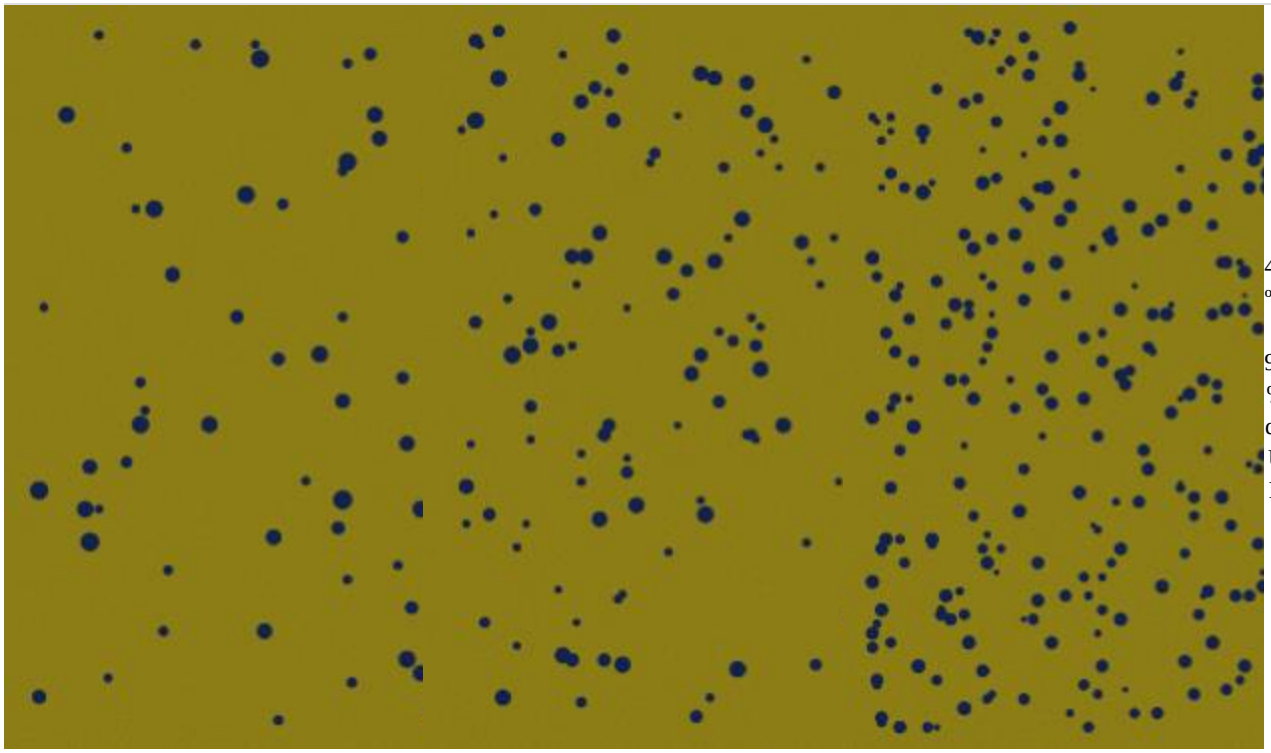


Image25 Image26 Image27

Um resultado interessante da geração das imagens, foi o fato de alguns pontos azuis terem se sobreposto na etapa de plotagem (FIGURA 1). Tal ocorrência é frequentemente observada em imagens reais (FIGURA 2) de etiquetas hidrossensíveis usadas em avaliações de pulverizações agrícolas. Nestes casos, a mancha na etiqueta causada por gota se mistura à mancha causada por outra gota. Casos em que isso acontece, trazem um maior desafio para os métodos de visão computacional determinarem características das gotas pulverizadas, a exemplo do seu diâmetro. Isso porque é necessário que o método consiga "entender" que determinadas manchas (e seu tamanho) correspondem a duas ou mais gotas.

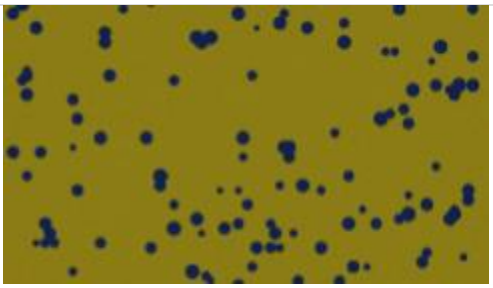


Image28

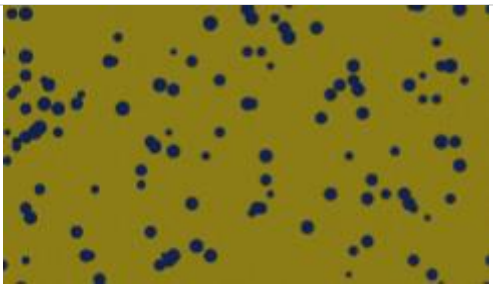


Image29

a) b)

FIGURA 1. Aproximação na imagem de exemplos de situação em que a mancha de 2 ou mais gotas se uniram. Os exemplos correspondem às condições de temperatura, umidade relativa e pressão de trabalho de, respectivamente: a) 40 ºC, 70% e 500 KPa; b) 20 ºC, 70% e 500 KPa.



Image30

FIGURA 2. Etiqueta hidrossensível real manchada por gotas de uma pulverização. Condições ambientais e pressão de trabalho desconhecidas. Fonte: Pinto (2016).

Borkiman et al. (2021) geraram um conjunto de dados sintéticos aleatórios contendo 400.000 imagens e anotações. En seu trabalho também foi possível coletar e anotar um conjunto de dados reais contendo 1.267 imagens de 63 itens de mercado. Os pesquisadores notaram que a performance dos modelos de visão computacional foi melhorada quando os dados sintéticos foram combinados aos dados reais para o treinamento dos modelos. Tal resultado aponta o uso de dados sintéticos em estudos de visão computacional tem grande potencial.

Assim como foi feito no estudo de Borkiman et al. (2021), a equipe do atual trabalho espera, em trabalhos futuros, treinar e testar modelos de visão computacional com a utilização de um conjunto de dados sintéticos. Sendo este conjunto referente às 27 imagens resultantes da análise do atual trabalho.

CONCLUSÃO

O uso de dados sintéticos em estudos de visão computacional apresentaram grande potencial, sendo os dados gerados capazes de emular ocorrências comuns existentes em etiquetas hidrossensíveis usadas em pulverizações reais.

AGRADECIMENTOS

Agradecemos a Fundação de Amparo a Ciência e Tecnologia do Estado de Pernambuco (FACEPE, Foundation for Supporting Science and Technology of the State of Pernambuco, Brazil) e a Universidade Federal Rural de Pernambuco pelo apoio.

REFERÊNCIAS

BORKMAN, Steve et al. Unity perception: Generate synthetic data for computer vision. **Unity Technologies**, 2021.

MACIEL, C.F.S. et al. Droplet spectrum at different vapour pressure deficits1. **Revista Ciência Agronômica**, v. 47, n. 1, p. 41-46, 2016.

PINTO, F. A. C. ENG 639 - Processamento digital de imagens (Notas de aulas). 2016.

FILTRAGEM AUTOMÁTICA DE DADOS DE PRODUTIVIDADE DE CANA-DE-AÇÚCAR

Eudocio Rafael Otavio da Silva [1]; Marcelo Chan Fu Wei [1]; Ricardo Canal Filho [1]; José Paulo Molin [2]
[1]Doutorando em Engenharia de Sistemas Agrícolas. Av. Pádua Dias, 235 - Agronomia, Piracicaba - SP, 13418-900. Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo; [2]Professor Titular. Av. Pádua Dias, 235 - Agronomia, Piracicaba - SP, 13418-900. Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
O monitoramento da produtividade da cana-de-açúcar em alta resolução espacial gera grande volume de dados, que incorporam ruídos intrínsecos à operação de colheita, sendo necessário removê-los. Os métodos de filtragem existentes ainda necessitam de intervenções humanas, impedindo sua automatização para uso nos grandes bancos de dados gerados atualmente. O presente estudo propõe uma técnica de filtragem automática de dados de colheita em canaviais visando automatizar o processo e aumentar a eficiência computacional. Foi desenvolvido um filtro baseado em algoritmo de janela deslizante implementado a um método de filtragem estatístico. Dois estudos de caso com dados reais de lavoura foram apresentados para demonstrar a eficácia do filtro proposto em detectar *outliers* de diferentes magnitudes (MO), comparados à filtragem por outro método da literatura. *Outliers* da produtividade de cana-de-açúcar com MO $\geq \pm$ 0,50 foram quase 100,00% detectados e cerca de 40,00% dos *outliers* artificias com MO de $\pm$ 0,01 foram identificados. O algoritmo proposto melhor preservou a variabilidade espacial da cultura em comparação ao método comparativo. Ainda, foram equivalentes na identificação de regiões com diferentes potenciais produtivos da cana-de-açúcar, refletindo a variabilidade existente. Portanto, o método proposto demonstra potencial para a filtragem de dados de colheitas em canaviais.

PALAVRAS-CHAVE: aprendizado de máquina; janela deslizante; *outlier*

ABSTRACT
Monitoring sugarcane yields in high spatial resolution generates a large volume of data, which incorporates noise intrinsic to the harvesting operation, which needs to be removed. Existing filtering methods still require human intervention, preventing them from being automated for use in the large databases generated today. This study proposes an automatic filtering technique for sugarcane harvesting data in order to automate the process and increase computational efficiency. A filter based on a sliding window algorithm implemented with a statistical filtering method was developed. Two case studies with real crop data were presented to demonstrate the effectiveness of the proposed filter in detecting outliers of different magnitudes (OM), compared to filtering by another method in the literature. Outliers in sugarcane yield with OM $\geq \pm$ 0.50 were almost 100.00% detected and around 40.00% of artificial outliers with OM of $\pm$ 0.01 were identified. The proposed algorithm better preserved the spatial variability of the crop compared to the comparative method. It was also equivalent in identifying regions with different sugarcane production potential, reflecting the existing variability. Therefore, the proposed method shows potential for filtering crop data in sugarcane plantations.

KEYWORDS: ;

INTRODUÇÃO

A cana-de-açúcar é cultivada em fileiras, colhida a cada uma ou duas fileiras e produz elevada biomassa com variações em curtas distâncias entre plantas e fileiras (MALDANER et al., 2022a). O monitoramento da biomassa na colheita mecanizada tem sido realizado por monitores de produtividade. Houve avanços substanciais nos últimos anos, como dados de produtividade em alta resolução espacial obtidos pela redistribuição da produção do canavial pelo dado de pressão de propulsão no picador da colhedora devidamente georreferenciado (MALDANER et al., 2022b). Este sistema gera volumosos conjuntos de dados que precisam ser processados para servirem como uma camada de informação na tomada de decisão agrícola. Entretanto, podem ocorrer erros nesses dados devido a diversos fatores, como tempo de posicionamento, problemas no controle de tráfego na fileira da cana, que pode provocar desalinhamento da colhedora, dificuldades no processo de alimentação da colhedora devido ao relevo, erros de leituras nos sensores embarcados na colhedora, paradas para manutenção da máquina em campo, problemas de *hardwar*e e *software* do computador de bordo, manobras de cabeceira, entre outros fatores (SPEKKEN et al., 2015; BRAUNBECK & OLIVEIRA, 2006). Logo, estes dados precisam ser filtrados para posterior utilização. A decisão de um analista de dados sobre quais dados devem ser removidos é complexa, e utiliza como suporte detectores de valores discrepantes (ou *outliers*, em inglês). Um *outlier* é uma observação que se desvia consideravelmente das demais no conjunto de dados. No entanto, nem todo *outlier* é um erro, pois determinados valores discrepantes podem apontar um fenômeno não caracterizado no conjunto de dados (MOKOENA et al., 2022). Os desafios da filtragem de dados para o contexto da agricultura são: (a) leis que regem a espacialidade precisam ser consideradas na análise da estrutura espacial de uma variável (e.g., Lei de Tobler) e critérios da matriz de vizinhança (e.g., contiguidade) (TOBLER, 1970); (b) os valores discrepantes podem afetar suposições de modelos estatísticos e geostatísticos; (c) ausência de estratégia unificada para detectar *outliers* (SMITI, 2020); (d) ausência de referência verdadeira sobre o *outlier* (LIU et al., 2021); (e) as configurações de limite do filtro não são conhecidas; e (f) a maioria dos métodos de filtragem de dados exigem parâmetros de entrada ajustáveis pelo usuário, inserindo subjetividade no processo (SOUIDEN et al., 2022), o que demanda automação na análise de dados. Por exemplo, o procedimento de filtragem no programa MapFilter 2.0 (MALDANER et al., 2022a) requer que o usuário insira o parâmetro de variação de limite nas etapas de filtragem global e local, e requer também a inserção manual do valor da dependência espacial da variável a ser filtrada. Logo, observou-se a necessidade de otimizar o procedimento para as especificidades da cana, propondo a automatização dos processos.

OBJETIVOS

O presente estudo propõe uma técnica de filtragem automática de dados de colheita em canaviais visando automatizar o processo e aumentar a eficiência computacional.

MATERIAL E MÉTODOS

Área de estudo e conjunto de dados

O estudo foi conduzido em dois canaviais comerciais no estado de São Paulo, Brasil, identificados como conjunto de dados 1 e 2. O conjunto de dados 1 abrange 10 talhões, totalizando 208,78 hectares, enquanto o conjunto de dados 2 é composto por 6 talhões com uma área total de 52,98 hectares (Tabela 1).

TABELA 1. Caracterização do conjunto de dados brutos para os conjuntos de dados 1 e 2.

Conjunto de dados	nº talhões	Área (ha)	nº pontos	Densidade (pontos ha^{-1})	Média prod. (Mg ha^{-1})
1	10	208,78	217521	1041,87	69,29

2	6	52,98	54281	1204,56	37,30

nº talhões: número de talhões; nº pontos: número de pontos; Média prod.: média da produtividade.

Neste estudo, a colheita foi realizada por colhedoras de cana, que cortam e processam uma única fileira por vez, que predomina no mercado. Os registros contíguos dos dados de produtividade de cana foram realizados durante o deslocamento da máquina ao longo da fileira de cana e estes dados foram armazenados em um computador de bordo integrado à colhedora. O mapeamento da produtividade foi realizado com um sistema comercial (Solinftec, Araçatuba, São Paulo, Brasil) baseado nas variações da propulsão hidráulica do sistema picador de colmos da colhedora (MALDANER et al., 2022b). A resolução espacial e a frequência de coleta dos dados de colheita foram determinadas pela variação de pressão do picador de colmos da colhedora. Neste estudo, os dados de colheita foram registrados com receptor GNSS com uma frequência de 0,20 Hz. Os dados possuem diferentes colunas e suas respectivas linhas com variáveis distintas. Os dados utilizados para o filtro proposto foram: coordenadas de latitude e longitude, produtividade e tempo de colheita. Assim, estes dados brutos foram transformados em uma matriz de dados. Ao executar o algoritmo, uma coluna da matriz foi selecionada e cada um dos registros de dados de colheita nas linhas correspondeu a um elemento dentro da janela deslizante (JD), com o tamanho da janela definido (janela deslizante univariada). Logo, se o tamanho da JD fosse igual a cinco, por exemplo, isso corresponderia ao registro de cinco pontos de colheita obtidos na lavoura e armazenados no arquivo, como mostra o esquema de obtenção da JD na colheita da cana (Figura 1).

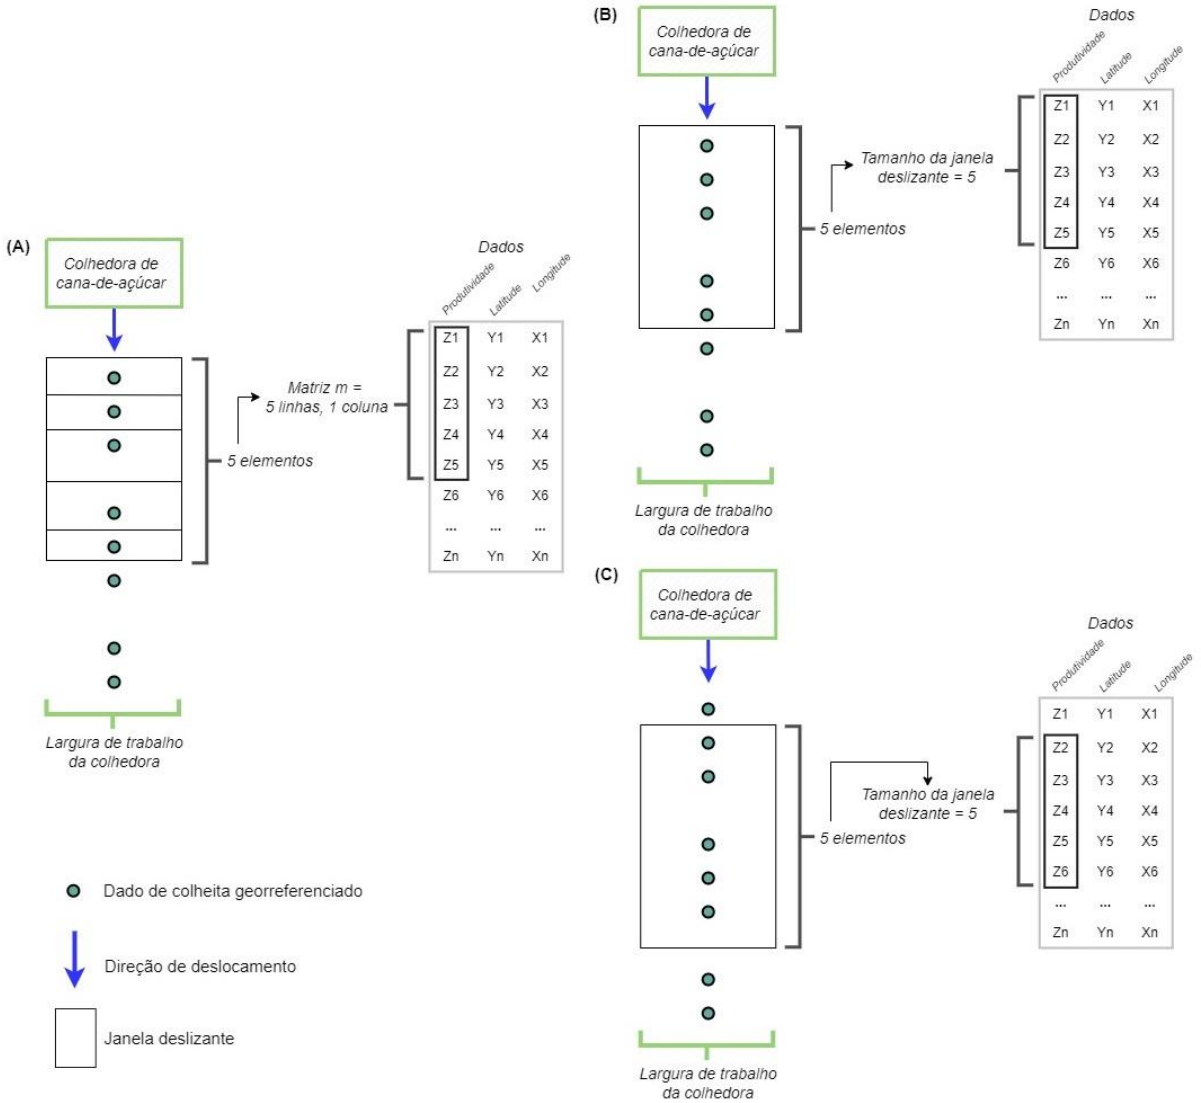


FIGURA 1. Esquema de obtenção da janela deslizante na colheita da cana-de-açúcar. Matriz de dados (A), construir a janela inicial (B), deslizar a janela de uma sublista para a próxima e deslizar repetidamente até o final da lista (C).

Desenvolvimento do algoritmo de janela deslizante

Uma janela é uma subsequência entre i-ésimo e o j-ésimo itens recebidos, denotado como W[*i*, *j*] = (x_i, x_{i+1},..., x_j), em que $i < j$, sendo *i* e *j* os itens na sequência de uma lista. No modelo de janela deslizante (JD), a janela W[$p - w + 1$, *p*], em que *p* é ponto de contagem atual dentro da janela e *w* é o tamanho da janela, sempre que uma nova instância chega, a JD é enfileirada em uma estrutura de dados de política FIFO (do inglês, *first-in, first-out*), na qual a mais antiga é descartada (SOUIDEN et al., 2022). O algoritmo de JD opera com base em determinados requisitos: uma matriz como entrada; elementos contíguos; uma janela que representa um intervalo de elementos; um estado para ser mantido nessa janela, neste caso, o filtro estabelecido para a filtragem de dados; e a iteração completa da matriz. No presente estudo, o algoritmo de JD foi desenvolvido e aplicado utilizando-se matrizes, no qual em sua execução os dados são atualizados constantemente dentro da janela, sendo gerados conjuntos de dados subjacentes a serem aplicados na filtragem. Zeng et al. (2023) destacam que o modelo de janela deslizante pode ser de dois tipos: baseado em contagem e baseado em tempo. No contexto deste estudo, a JD foi baseada em contagem, o que significa que sempre conterá um número fixo de dados que representam o tamanho da JD. O método de filtragem é baseado em estatística, utilizando a mediana do conjunto de dados. Neste método, estabelece-se o limite superior (LS) e inferior (LI) correspondente ao intervalo de valores considerados representativos do conjunto de dados (do inglês, *inliers*). Valores acima e abaixo do LS e LI são considerados discrepantes e podem ser removidos do conjunto de dados (Equações 1 e 2).

$$Limite\ superior\ (LS) = Med_i + Med_i \times f \quad \text{Eq. (61)}$$

$$Limite\ inferior\ (LI) = Med_i - Med_i \times f \quad \text{Eq. (62)}$$

em que: Med_i - mediana dos valores localizados dentro da janela deslizante; e *f* - fator de variação máximo aceita para a mediana.

O algoritmo de filtragem automatizado proposto constitui-se de três etapas, representadas por *i*, *ii* e *iii* (Figura 2). As etapas *i* e *iii* tem como objetivo destrinçar os dados e a etapa *ii* visa detectar *outliers* com um valor fixo de limiar de dispersão.

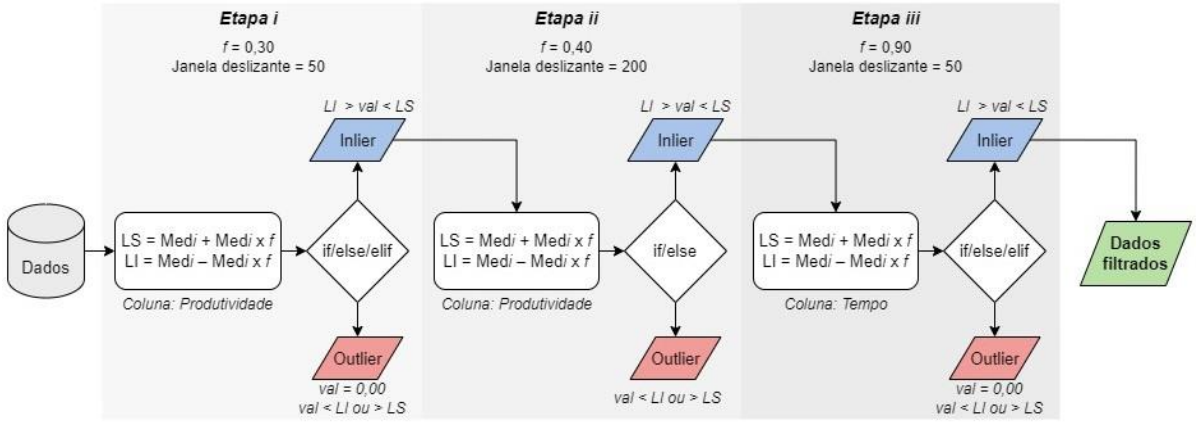


FIGURA 2. Estrutura do algoritmo de filtragem proposto. Med_i: mediana dos valores localizados dentro da janela deslizante; *f*: fator de variação máximo aceito para a mediana; LI: limite inferior; LS: limite superior; val: valor.

Etapa i: Automaticamente, com o fator *f* igual 0,30 e o tamanho da JD igual a 50 a coluna "produtividade" do conjunto de dados é selecionada para a realização da filtragem. Os valores de

limites superior e inferior são obtidos e são variáveis ao longo da execução do algoritmo, sendo esta variação devido ao tamanho da JD, fator *f* e aos valores do conjunto de dados dentro da JD. Na execução do algoritmo, a janela desliza sob a matriz de dados e realiza a operação de filtragem, verificando os dados um a um. A cada momento que a janela desliza na matriz de dados, novos limites superior e inferior são obtidos e a filtragem do subconjunto de dados é realizada e cada valor é verificado se corresponde a um valor presente no intervalo do limite superior e inferior. Se o valor estiver dentro do intervalo de filtragem, corresponde a um *inlier* e é mantido no conjunto de dados (*if*); entretanto, se o valor não estiver dentro do limite inferior e superior, é considerado um dado discrepante e é removido do conjunto de dados (*else*). Se o dado de produtividade for igual a zero (0) também é considerado um dado discrepante e é removido (*elif*). Esta operação é finalizada ao iterar em toda a coluna de produtividade da matriz de dados. Ao final da etapa *i* é obtido um conjunto de dados filtrados que é automaticamente inserido na etapa *ii*.

Etapa ii: Os dados filtrados na etapa anterior são transformados novamente em uma matriz de dados e a coluna 'produtividade' é selecionada novamente para a filtragem dos dados. O tamanho da JD é igual a 200 e fator *f* igual a 0,40. Assim como a etapa *i*, a estrutura condicional *if* e *else* ocorre enquanto a janela desliza e realiza a filtragem do conjunto de dados. A etapa *ii* termina ao iterar toda a matriz de dados e o conjunto de dados filtrados são automaticamente inseridos na etapa *iii*.

Etapa iii: A coluna "tempo" é selecionada e filtrada. Esta coluna refere-se ao tempo de armazenamento da coleta de um dado em um ponto na lavoura. O tamanho da JD corresponde a 50 e o fator *f* nesta etapa é igual a 0,90. A estrutura condicional *if, else* e *elif* ocorre enquanto a janela desliza na matriz de dados e realiza a filtragem do conjunto. Ao final desta etapa, são geradas como saída o conjunto de dados filtrados da colhedora, a estatística descritiva destes dados e o mapa de produtividade da cana dos campos analisados.

Validação

Para avaliar o desempenho do método proposto, foram inseridos artificialmente valores discrepantes nos conjuntos de dados. Desta maneira, a avaliação do desempenho na detecção de valores discrepantes baseou-se no número de *outliers* artificiais de diferentes magnitudes detectados, uma vez que o número de *outliers* introduzidos é conhecido (LIU et al., 2021). Para isso, foram selecionados aleatoriamente diferentes elementos nos conjuntos de dados, a partir dos quais *outliers* artificiais foram gerados. Nos pontos selecionados, os valores de produtividade foram submetidos a diferentes magnitudes de *outliers* (MO) (LIU et al., 2021), sendo MO = ± 0,01, ± 0,05, ± 0,10, ± 0,50, ± 0,80 e ± 1,00, que representam *outliers* de pequena, média e grande magnitude (Equação 3).

$$Z_0 = Z + MO \times Z \quad \text{Eq. (63)}$$

em que: Z - valor original de um elemento; Z_0 - valor do *outlier* artificial; e MO - magnitude do *outlier*, sendo ± 0,01, ± 0,05, ± 0,10, ± 0,50, ± 0,80 e ± 1,00.

Os conjuntos de dados 1 e 2 foram contaminados com 4944 e 1464 valores discrepantes artificiais, representando cerca de 2,30 e 2,70% do número total de dados, respectivamente. A partir disso, avaliou-se o desempenho na detecção de *outliers* artificiais para o algoritmo proposto comparando com o MapFilter 2.0 (MALDANER et al., 2022a), um método de filtragem de dados de alta densidade em lavouras que emprega filtragem global (a mediana do conjunto de dados para calcular os limites inferior e superior) e filtragem local (limites inferior e superior são determinados a partir da mediana dos dados localizados em uma faixa de raio ao redor de um ponto de forma aniso e isotrópica, ou seja, no sentido da fileira de cultivo e não considerando a disposição das fileiras, respectivamente). Os parâmetros inseridos no MapFilter 2.0 utilizados no presente estudo foram: variação de limite igual 30,00% (filtragem global), dependência espacial igual a 200,00 m e variação de limite correspondente a 30,00% (filtragem local). Foram analisadas as estatísticas descritivas dos dados submetidos ao método proposto e ao método desenvolvido por Maldaner et al. (2022a). Os dados filtrados foram

espacializados utilizando o Sistema de Informação Geográfica (SIG) QGIS v. 3.22.10. Os *outliers* removidos foram identificados quanto às operações de deslocamento, parada e manobra da colhedora no campo e espacializados. O desenvolvimento do algoritmo e todas as análises desenvolvidas neste estudo foram realizados por meio do ambiente virtual *JupyterLab*, utilizando a linguagem de programação Python v. 3.10.5 (KLUYVER et al., 2016; PYTHON, 2024).

RESULTADOS E DISCUSSÃO

Foram identificados valores discrepantes de 59,67% e 59,11% no conjunto de dados 1 e 42,45% e 41,17% no conjunto de dados 2 pelo algoritmo proposto neste trabalho e pelo método comparativo, respectivamente. O MapFilter 2.0 removeu uma quantidade relativamente menor de pontos (Tabela 2). A redução de dados após o processo de filtragem é uma observação comum em limpezas desse tipo de dados. Em Maldaner & Molin (2020), utilizando o MapFilter 2.0 para filtrar conjuntos de dados de monitores de produtividade de colhedoras de cana, foram removidos valores que alcançaram até 40,00% do conjunto de dados, caracterizados como discrepantes. Mesmo após a filtragem, a densidade de pontos pelo método proposto é considerável, com valores iguais a 87723 e 31238 pontos, representando cerca de 420 e 590 pontos ha^{-1} nos conjuntos de dados 1 e 2, respectivamente. A execução das três etapas do algoritmo demandou um tempo de processamento de 91,49 s e 20,68 s para os conjuntos de dados 1 e 2. Esses valores estão diretamente relacionados à premissa do algoritmo de janela deslizante, que visa minimizar a complexidade de tempo da operação (ZENG et al., 2023).

TABELA 2. Estatísticas da produtividade para os dados brutos e pelos métodos de filtragem nos conjuntos de dados 1 e 2.

Conjunto de dados	Método	n	% dados removidos	média	min	max	DP	CV (%)
				Mg ha^{-1}				
1	Dados brutos	217521	-	69,29	0,00	752,84	42,64	61,54
	Algoritmo proposto	87723	59,67	83,88	29,04	178,05	18,66	49,63
	MapFilter 2.0	88940	59,11	79,75	53,77	99,83	11,26	14,12
2	Dados brutos	54281	-	37,30	0,00	647,30	22,88	61,34
	Algoritmo proposto	31238	42,45	47,29	1,39	126,18	7,87	30,99
	MapFilter 2.0	31934	41,17	47,42	31,73	58,31	5,62	11,86

n: número de dados; min: mínimo; max: máximo; DP: Desvio padrão; CV: Coeficiente de variação.

O algoritmo de JD preservou maior amplitude de valores de produtividade, indicados pelos valores mínimos e máximos, e demonstrou maior variabilidade dos dados nos canaviais em comparação com o MapFilter 2.0, evidenciado pelos valores de CV e DP. Isso é relevante, pois a cana-de-açúcar apresenta alta variabilidade de biomassa em curtas distâncias (MALDANER et al., 2022a), entre fileiras e entre plantas, sugerindo que o algoritmo de JD conseguiu lidar com a variabilidade da produtividade nos canaviais. Em relação aos dados médios, o filtro proposto apresentou valores superiores, porém próximos aos valores do filtro comparativo. Esses resultados estão associados às maiores amplitudes de dados obtidas. O algoritmo demonstrou habilidade na identificação de valores discrepantes, alinhando-se de maneira consistente com uma avaliação manual, especialmente no que diz respeito aos dados de produtividade que extrapolam o padrão de produção para a cana-de-açúcar (por exemplo, valores superiores a 300,00 Mg ha^{-1}, assim como valores de 752,84 e 647,30 Mg ha^{-1}

verificados nos conjuntos de dados 1 e 2, respectivamente) e aos registros de tempo de armazenamento da informação de colheita no computador de bordo da colhedora (com valores acima de 20,00 s, por exemplo). Isso é relevante considerando-se que o tempo médio de coleta de dados é de 5 segundos (frequência de 0,20 Hz). Verifica-se que os valores discrepantes em determinados intervalos, como os valores exemplificados anteriormente, coincidem com aquilo que o olho humano identificaria como *outliers*, o que aumenta a confiança do filtro proposto para automação de tarefas morosas e repetitivas. Uma vantagem do método proposto em relação ao MapFilter 2.0 é que não requer a inserção de valores pelo usuário como parâmetros de entrada para a filtragem de dados, automatizando assim o processo e solucionando a problemática comum de diversos métodos de filtragem, a subjetividade (SOUIDEN et al., 2022). Além disso, o filtro proposto apresenta tempo de processamento otimizado, pois além do tempo de execução do algoritmo ser relativamente curto, a não necessidade de conhecer previamente o banco de dados da colheita da cana-de-açúcar para o estabelecimento de parâmetros a serem inseridos manualmente para realizar a filtragem poupa o tempo do usuário que analisa esses dados. Os resultados dos testes para detectar os valores discrepantes artificiais nos dados de colheita da cana são apresentados na Tabela 3.

TABELA 3. Desempenho de detecção de *outliers* artificiais (%) pelo método de filtragem proposto e pelo MapFilter 2.0.

Conjunto de dados	Método	Magnitude do *outlier*					
		± 0,01	± 0,05	± 0,10	± 0,50	± 0,80	± 1,00
1	Algoritmo proposto	48,79	46,72	45,75	89,44	96,60	97,33
	MapFilter 2.0	100,00	100,00	99,27	98,18	94,54	99,88
2	Algoritmo proposto	31,15	30,74	28,28	92,21	96,72	97,54
	MapFilter 2.0	100,00	100,00	98,36	97,95	100,00	99,59

Verificou-se, a partir da Tabela 3, que para MO $\geq \pm$ 0,50, o desempenho de detecção de *outliers* artificiais do método proposto e do MapFilter 2.0 apresentaram valores próximos a 100,00%. Para MO = ± 0,01, ± 0,05 e ± 0,10, o desempenho foi reduzido nesta ordem. O método proposto exibiu degradação de desempenho em comparação com o método comparativo, MapFilter 2.0. Isso não é desejado, entretanto faz sentido ao considerar que o método proposto apresenta variação nos limites da JD quanto ao que é considerado *outlier* e *inlier*, à medida que a janela desliza no arquivo de dados. Portanto, para os conjuntos de dados 1 e 2, os valores de menor magnitude tornaram-se mais difíceis de serem detectados, uma vez que o limiar de *outlier* depende do subconjunto de dados gerado na JD. O MapFilter 2.0 detectou 100,00% de *outliers* artificiais de menor magnitude, evidenciando a sua robustez. No entanto, observou-se que o mesmo apresentou intervalos de valores da produtividade de menor amplitude e menor variação de limites no conjunto de dados comparado ao método de JD proposto. Isto pode não ser tão favorável para a filtragem de dados, uma vez que há o risco de eliminar dados legítimos que, embora correspondam a dados reais do campo, não se encontram nos limites estabelecidos pelo filtro. Neste aspecto, o método proposto se destacou positivamente, pois preservou os intervalos mais amplos de dados, permitindo assim a retenção de informações que refletem a variabilidade existente no campo. É relevante destacar a complexidade inerente à definição de um limiar que identifique de maneira acurada os dados discrepantes. O subconjunto gerado pela janela deslizante torna esse limiar mais específico, pois compreende os dados de maneira localizada. Quanto maiores forem as tolerâncias, menos falsos positivos ou falsos *outliers* serão identificados. Isso ocorre porque o algoritmo tolera valores maiores nos limites da JD. No entanto, grandes tolerâncias também resultam em muitos falsos negativos, ou seja, valores discrepantes perdidos. No presente estudo, o limiar depende do tamanho da janela deslizante e do fator *f*, o que leva o algoritmo a possuir configurações distintas em cada etapa (*i*, *ii*, *iii*) e, portanto, tolerâncias distintas. A primeira etapa

possui uma menor tolerância em relação às outras, principalmente porque os dados são inseridos pela primeira vez no filtro. Assim, o limiar é variável e de menor tolerância, quando comparado aos das etapas seguintes. Na etapa *ii*, esse limiar variável é mais amplo porque o fator *f* é maior e o conjunto de dados iterou *n* vezes em subconjuntos maiores que o da etapa *i*. Desta maneira, são identificados e removidos os dados que talvez não pudessem ser detectados com determinados valores de limiar de dispersão. A configuração da etapa *iii* permite um limiar variável que possibilita uma maior amplitude dos dados, considerando o fator *f*, e uma quantidade de elementos na janela que geraram subconjuntos adequados para detectar os valores discrepantes de tempo de armazenamento dos dados de produtividade no computador de bordo da colhedora. Apesar das diferenças em determinados parâmetros estatísticos e das respostas quanto ao desempenho de detecção de valores discrepantes, os métodos de filtragem foram equivalentes na identificação de regiões com diferentes potenciais produtivos da cana-de-açúcar no campo. Logo, o método proposto permitiu a retenção de dados que refletem a variabilidade da produtividade existente nos canaviais (Figura 3).

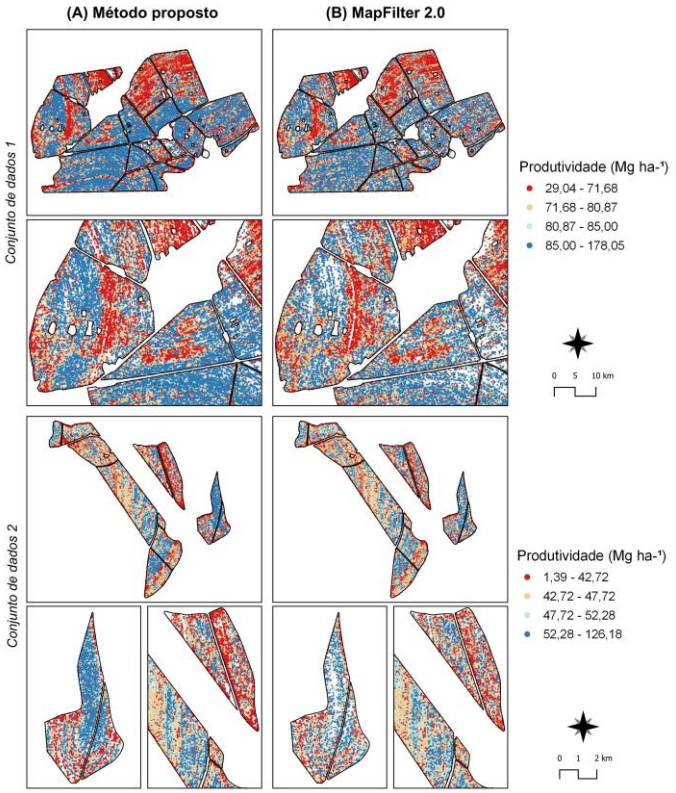


FIGURA 3. Caracterização da produtividade da cana indicados por pontos gerados a partir dos conjuntos de dados 1 e 2 filtrados pelo método proposto neste estudo (A) e pelo MapFilter 2.0 (B).

Adicionalmente, constatou-se que o método proposto identificou e removeu do conjunto de dados registros relacionados a operações de deslocamento da colhedora no campo (Fig. 4A). Esses dados incluem dados relacionados ao movimento da máquina da gleba anterior, deslocamento entre talhões e nos carreadores. Além disso, foram detectados e removidos dados correspondentes à parada da máquina na lavoura para a troca da lâmina de corte, manutenção corretiva, falta de caminhão para reabastecimento/descarregamento da cana colhida, lavagem e limpeza de equipamentos (Fig. 4B). Estes dados, com tempos de operação superiores aos de colheita e com valores de produtividade apontados como iguais a zero, visto que é uma operação em que não estava sendo efetivamente realizada a colheita, foram facilmente identificados pelo método proposto.

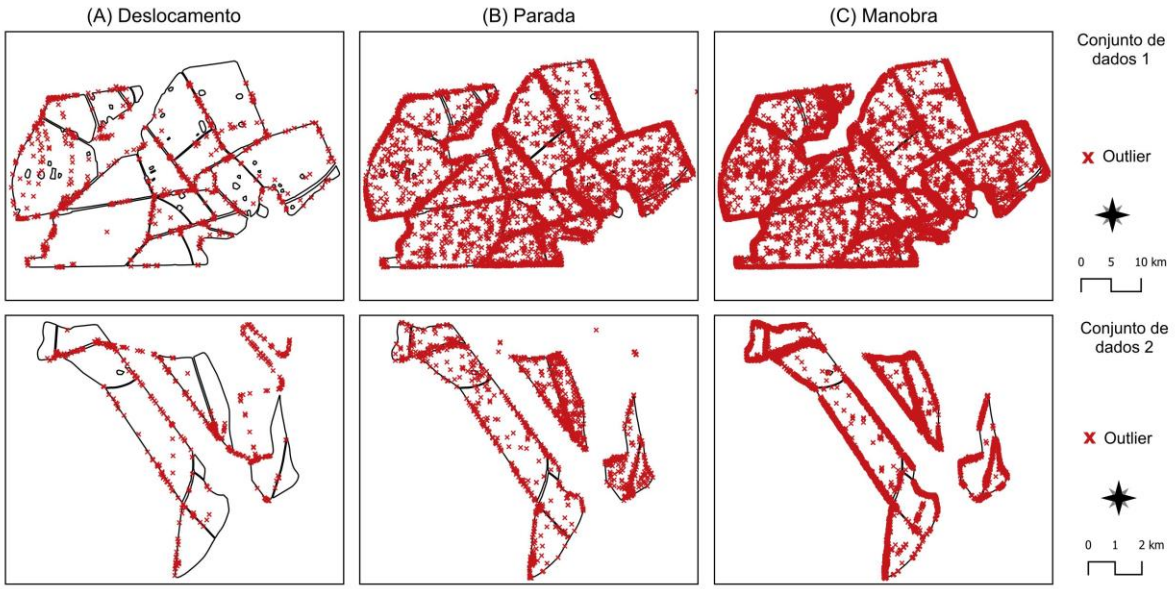


FIGURA 4. Detecção de valores discrepantes pelo método correspondentes às operações de deslocamento (A), parada (B) e manobra (C) da colhedora no canavial nos conjuntos de dados 1 e 2.

Para os dados armazenados como manobras (Fig. 4C), houveram duas fontes para a identificação de dados discrepantes pelo filtro proposto: a produtividade igual a zero e o tempo para manobra que superava o tempo de armazenamento de um dado efetivo de colheita (valores de até 60 s). Como pode ser observado, houve pontos localizados dentro dos talhões em regiões que não possuem carreadores, que foram registrados como um dado referente à manobra, possivelmente sendo um erro operacional, entretanto foram removidos porque os dados de produtividade nestes pontos eram nulos. Estes tipos de dado gerados no campo ocorrem em canaviais devido i) a talhões com fileiras mais longas e sem segmentação através do cruzamento de carreadores, atingindo a capacidade de colheita em locais distantes das estradas onde podem ser descarregados/reabastecidos (SPEKKEN et al., 2015), sendo gerados dados como os da Figura 4B. ii) Comprimentos de fileiras muito curtos, ocasionando a maior ocorrência de dados de manobra. Além de não serem rentáveis econômico e energeticamente, como verificado por Spekken et al. (2015); iii) necessidade de mais estudos de otimização de rotas na colheita mecanizada da cana-de-açúcar (SANTORO et al., 2017; SPEKKEN et al., 2015). Todos esses fatores e características da colheita da cana-de-açúcar resultam em dados com peculiaridades que precisam ser processados por meio de filtros para a geração de informação do canavial. Os dois conjuntos de dados relatados neste estudo foram originados com dados reais obtidos do cotidiano em operações agrícolas de colheita realizadas em canaviais. O método de detecção e remoção de *outliers* proposto é simples, não demanda de hardware especializado e é computacionalmente otimizado para grande volume de dados. Todos estes fatores garantem que a filtragem proposta pode ser utilizada em outros cenários de colheitas em canaviais. Como limitações, a filtragem proposta cumpre sua tarefa em fenômenos anisotrópicos (na direção da colheita na fileira) e são necessários estudos que verifiquem a estrutura espacial da produtividade da cana considerando o fenômeno isotrópico. Adicionalmente, verificou-se que foram removidos uma quantidade significativa de dados brutos e isso reflete um debate atual acerca do tratamento de dados obtidos por sensores em alta resolução espacial: um analista de dados agrícolas deve estar atento não apenas à quantidade de dados obtidos na lavoura, mas também à qualidade desses dados.

CONCLUSÃO

A filtragem proposta é automática e não necessita da inserção manual de parâmetros de entrada, o que evita tomadas de decisão subjetivas. O filtro proposto foi capaz de detectar quase 100,00% dos *outliers* de maiores magnitudes, como esperado, e cerca de 40,00% dos *outliers* de menor magnitude.

Observou-se que a filtragem proposta preservou os intervalos mais amplos de dados e apresentou resultados equivalentes na identificação de regiões com diferentes potenciais produtivos da cana-de-açúcar no campo em comparação ao método de filtragem comparativo (MapFilter 2.0). Portanto, o método proposto permitiu a retenção de dados que refletem a variabilidade existente lavoura e pode ser utilizado para a filtragem de dados de colheitas em canaviais.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. À Solinftec pelo suporte na obtenção dos dados.

REFERÊNCIAS

BRAUNBECK, O. A.; OLIVEIRA, J. T. A. Colheita de cana-de-açúcar com auxílio mecânico. **Engenharia Agrícola**, v. 26, n. 1, p. 300-308, 2006.

KLUYVER, T.; RAGAN-KELLEY, B.; PÉREZ, F.; GRANGER, B.; BUSSONNIER, M.; FREDERIC, J. et al. Jupyter Notebooks - a publishing format for reproducible computational workflows. *In*: LOIZIDES, F.; SCHMIDT, B. (Eds.). **Positioning and Power in Academic Publishing**: Players, Agents and Agendas. Amsterdã: IOS Press, 2016. p. 87-90.

LIU, J.; LIU, L.; DU, J.; SANG, J. TLE outlier detection based on expectation maximization algorithm. **Advances in Space Research**, v. 68, n. 7, p. 2695-2712, 2021.

MALDANER, L. F.; MOLIN, J. P.; SPEKKEN, M. Methodology to filter out outliers in high spatial density data to improve maps reliability. **Scientia Agricola**, v. 79, n. 1, e20200178, 2022a.

MALDANER, L. F.; CANATA, T. F.; MOLIN, J. P. An Approach to Sugarcane Yield Estimation Using Sensors in the Harvester and ZigBee Technology. **Sugar Tech**, v. 24, p. 813-821, 2022b.

MALDANER, L. F.; MOLIN, J. P. Data processing within rows for sugarcane yield mapping. **Scientia Agricola**, v. 77, n. 5, e20180391, 2020.

MOKOENA, T.; CELIK, T.; MARIVATE, V. Why is this an anomaly? Explaining anomalies using sequential explanations. **Pattern Recognition**, v. 121, 108227, 2022.

PYTHON. **A Biblioteca Padrão do Python**, 2024. Disponível em: <https://docs.python.org/pt-br/3/library/index.html>. Acesso em Jan 2024.

SANTORO, E.; SOLER, E. M.; CHERRI, A. C. Route optimization in mechanized sugarcane harvesting. **Computers and Electronics in Agriculture**, v. 141, p. 140-146, 2017.

SMITI, A. A critical overview of outlier detection methods. **Computer Science Review**, v. 38, 100306, 2020.

SPEKKEN, M.; MOLIN, J. P.; ROMANELLI, T. L. Cost of boundary manoeuvres in sugarcane production. **Biosystems Engineering**, v. 129, p. 112-126, 2015.

SOUIDEN, I.; OMRI, M. N.; BRAHMI, Z. A survey of outlier detection in high dimensional data streams. **Computer Science Review**, v. 44, 100463, 2022.

TOBLER, W. R. A computer movie simulating urban growth in the Detroit region. **Economic Geography**, v. 46, p. 234-240, 1970.

ZENG, Z.; CUI, L.; QIAN, M.; ZHANG, Z.; KAIMIN WEI, K. A survey on sliding window sketch for network measurement. **Computer Networks**, v. 226, 109696, 2023.

TRATAMENTO DE DADOS DE MONITOR DE COLHEITA DE CANA-DE-AÇÚCAR PARA MAPEAMENTO DA PRODUTIVIDADE

Bruna da Silva Brito Ribeiro [1]; Rodrigo Greggio de Freitas [2]; Lucas Rios do Amaral [3]
[1]Mestranda . Campinas, SP. Universidade Estadual de Campinas; [2]Doutorando. Campinas, SP. Universidade Estadual de Campinas; [3]Docente. Campinas, SP. Universidade Estadual de Campinas

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
O monitoramento da produtividade de cana-de-açúcar por sensores óticos instalados na colhedora é relativamente novo. Diversos fatores podem interferir nos dados advindos desses monitores, resultando em interpretação errônea quanto à variabilidade presente nos canaviais. Com este trabalho objetivou-se apresentar didaticamente etapas do processo de pré-tratamento dos dados para a instrução de usuários ou interessados na produção de mapas de produtividade a partir de dados registrados por monitores de colheita de cana-de-açúcar. Os dados utilizados na análise são de uma única colhedora de cana-de-açúcar (*Saccharum officinarum* L.) equipada com monitor de produtividade, e são referentes a colheita de aproximadamente 102 ha no estado de São Paulo, na safra 2023. O tratamento dos dados foi dividido em sete etapas de filtragem. Após as filtragens, ficou claro que se deve estabelecer uma rotina mínima de verificação e edição de dados, sendo fundamental para a disseminação do correto uso da informação gerada pelos monitores de produtividade de cana-de-açúcar.

PALAVRAS-CHAVE: filtragem de dados; mapa de produtividade; pré-tratamento de dados

ABSTRACT
Sugar cane yield monitoring using optical sensing installed in a harvester is a relatively new technology. Several factors may interfere with the data registered by such yield monitors, leading to a misinterpretation of sugarcane field variability. The aim of this work was to present didactic steps in the data pre-processing process to instruct users or those interested in producing productivity maps from data recorded by sugarcane harvest monitors. A single harvester equipped with a yield monitor provided the data from an area of 102 ha located in São Paulo, in 2023. The data treatment was split into seven filtering stages. Throughout the stages, the importance to establish minimal data checking and spread the correct use of information from sugarcane yield monitors was confirmed.

KEYWORDS: ;

INTRODUÇÃO

Com a evolução tecnológica dentro do setor canavieiro no Brasil, existe o interesse pela implantação e a implementação da agricultura de precisão por parte dos produtores (Grego *et al.* 2014). As informações advindas do monitor de produtividade permitem, além do conhecimento da produtividade média por área, inferir sobre a variabilidade existente dentro dos talhões segundo Olsen e Hussey (2015). Apesar de sensores e novas tecnologias estarem sendo desenvolvidas para obtenção de dados de produtividade com qualidade, ainda são notados registros de dados equivocados que precisam ser depurados para obtenção de mapas realistas. No processo de filtragem de dados Menegatti e Molin (2004) detectaram em monitores de produtividade de diversas culturas, erros grosseiros de posicionamento, produtividade nula ou discrepantes, erros referentes a largura de plataforma, o que para o monitor de produtividade cana-de-açúcar também é possível ocorrer. Portanto, para geração de mapas fidedignos é importante a análise dos dados e a remoção ou correção

cuidadosa das inconsistências. Contudo, os trabalhos disponíveis na literatura sobre isso focam em colhedoras de grãos (Liu *et al*., 2022; Arslan e Colvin, 2002) ou em monitor de cana-de-açúcar baseado em balança instalada no elevador da colhedora (Magalhães e Cerri, 2007). Porém, como a tecnologia de monitoramento da produtividade por meio de sensor ótico instalado no elevador da colhedora ainda é recente para a cana-de-açúcar (Deere, 2024), se faz necessário explorar esses dados e entender as inconsistências existentes e como lidar com elas.

OBJETIVOS

Com este trabalho se objetivou apresentar didaticamente etapas do processo de tratamento dos dados para a instrução correta de usuários ou interessados na produção de mapas de produtividade, a partir de dados registrados por monitores de colheita de cana-de-açúcar.

MATERIAL E MÉTODOS

O conjunto de dados utilizados na análise são provenientes de uma única colhedora de cana-de-açúcar equipada com monitor de produtividade da marca John Deere Os dados são referentes a colheita de aproximadamente 102 ha, no estado de São Paulo, na safra 2023, em uma área composta por seis talhões vizinhos de cana-de-açúcar (*Saccharum officinarum* L.). Foram duas variedades colhidas na área: variedade SP80-3280 e a variedade CTC-4. A primeira ação foi a plotagem espacializada dos dados brutos, de forma a fornecer uma ideia geral sobre a área e operação realizada, assim como a magnitude das inconsistências existentes. O conjunto de dados continha uma série de atributos, sendo que os principais verificados na primeira checagem foram: produtividade, largura de corte, variedade, número de máquina, velocidade e distância colhida. Logo após, iniciamos um processo, passo a passo, com sete etapas para tratamento dos dados (Figura 1).

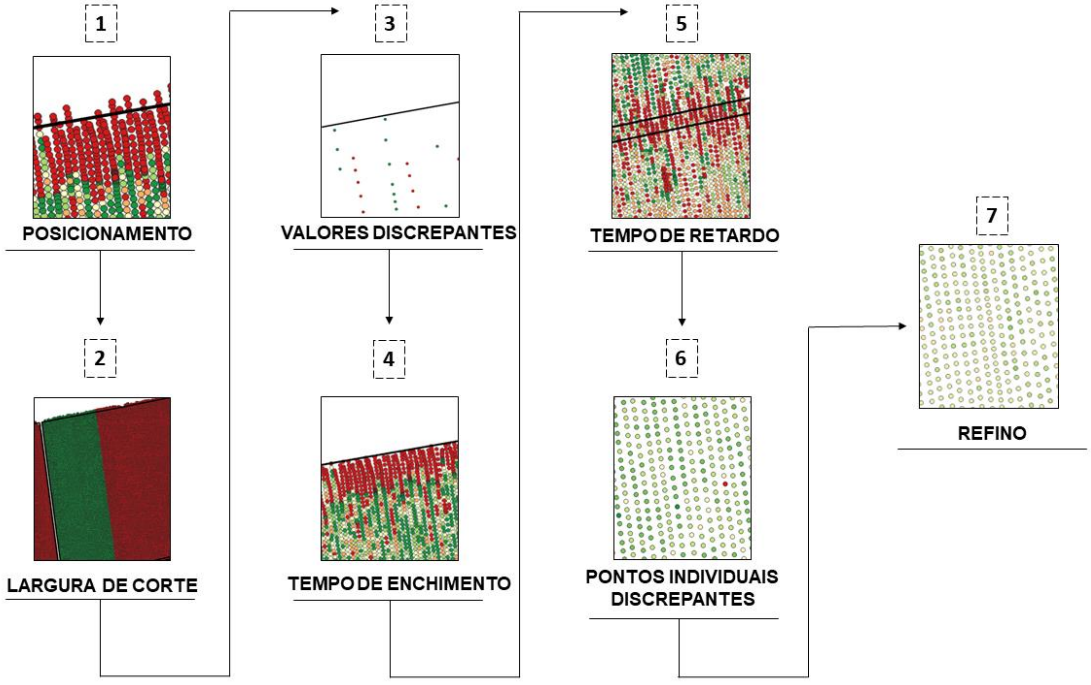


FIGURA 1. Recortes da área para exemplificar as etapas para a remoção dos erros do conjunto de dados de produtividade de cana-de-açúcar.

A primeira etapa (**Posicionamento - P**), foi a remoção de pontos com problemas de posicionamento (Figura 2A), ou seja, erros de georreferenciamento caracterizados por pontos fora da área de interesse, o que pode ocorrer por falha no GNSS da colhedora ou pelo registro de pontos nas manobras fora do

talhão. A segunda etapa (**Largura de corte -LC**) consistiu na correção do dado da largura de corte, pois o operador configurou erroneamente uma parte do trabalho com largura de 1,8m ao invés da largura de 1,5m. Isto gerou toda uma faixa com produtividade mais baixa que o restante da área, mas que poderia ser facilmente interpretada como região de baixa produtividade (Figura 2B). Ao avaliarmos a largura de corte na base de dados, notamos que estava configurada errada. Os dados de produtividade nesta área foram corrigidos com a conversão dos valores, multiplicando a produtividade registrada por 1,2 (divisão da largura errada (1,8 m) pela correta (1,5 m)). A terceira etapa (**Valores discrepantes-VD**) foi para a remoção de valores de produtividade extremos, pois havia valores superiores a mil toneladas, obviamente um erro de medição; assim, eliminamos todos os pontos acima de 300 t.ha^{-1} (Figura 2C), o que ainda pode ser considerada produção muita alta, mas que uma vez confirmados como erros, seriam eliminados nas próximas etapas.

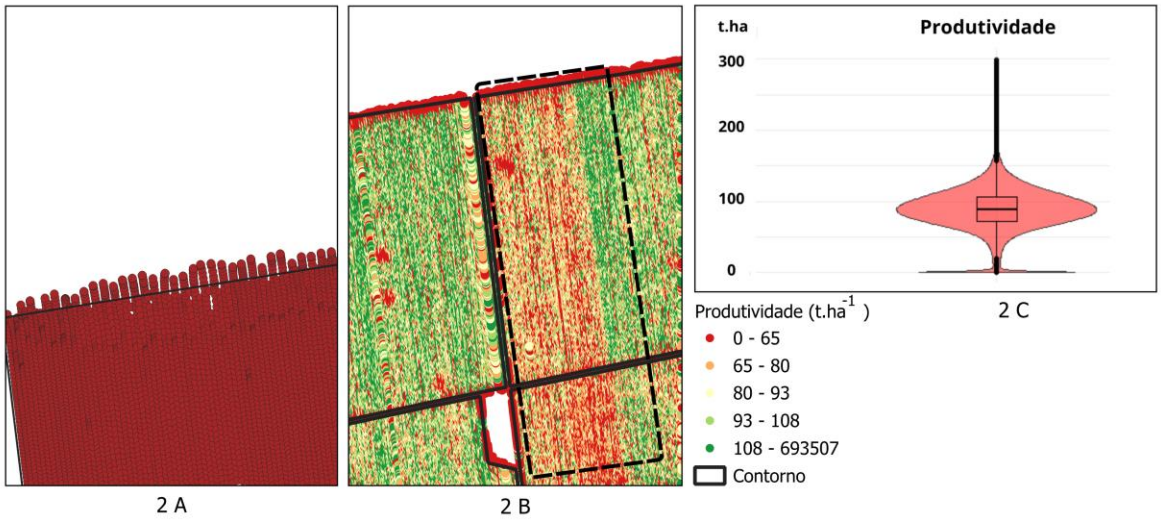


FIGURA 2. Recorte de uma parte da área para exemplificar os erros tratados nas etapas de 1 a 3: 2A - posicionamento; 2B - Largura de corte; 2C - Boxplot após corte de valores discrepantes (> 300 t.ha^{-1}).

A quarta etapa (**Tempo de enchimento-TE**) foi necessária para corrigir um padrão sistemático de baixa produtividade na entrada dos talhões (Figura 3). Esse erro pode ocorrer por duas razões relativas ao procedimento operacional das máquinas: 1) antes da colhedora iniciar o corte de nova linha de cana-de-açúcar, toda a cana-de-açúcar presente no sistema de processamento da máquina é transferida para o transbordo; ou 2) o aguardo no pareamento do transbordo, onde a colhedora se desloca alguns metros colhendo, mas com o elevador desligado. Esse comportamento aconteceu em praticamente toda a área colhida, mas o fato de apresentar padrão alternado (linha sim, linha não - Figura 3), fica evidente que é causado por questões operacionais. Assim, caso esse dado fosse mantido, as interpretações a respeito desta informação poderiam ser errôneas ao identificar que as bordaduras poderiam ter baixa produção. Contudo, utilizou-se imagens do satélite PlanetScope, com resolução espacial de 3,0 m, uma semana antes da colheita para confrontar com os dados de produtividade. Não foram verificadas áreas de baixo vigor ou ausência de plantas nas entradas dos talhões. Por essa razão, eliminamos valores entre 0 e 6 t.ha $^{-1}$ registrados principalmente nos primeiros 20 m a partir da entrada do talhão.

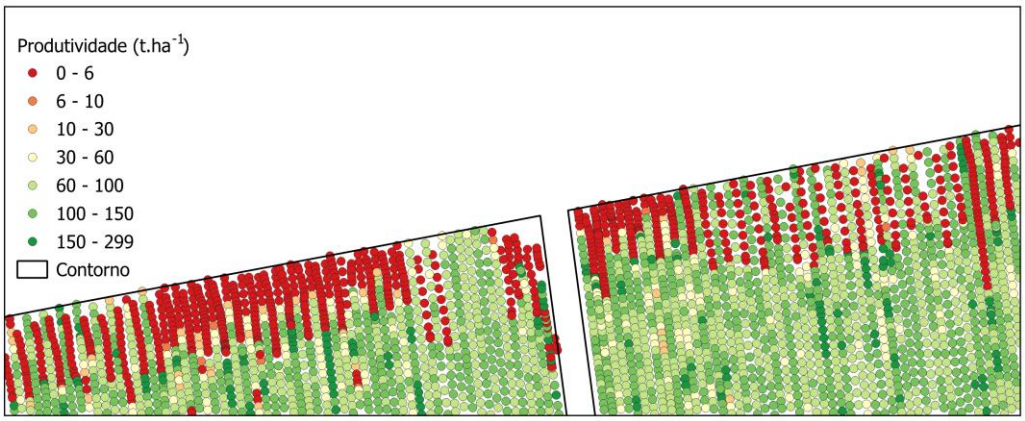


FIGURA 3. Recorte de uma parte da área para exemplificar os ados inconsistentes (vermelho) de baixa produtividade na bordadura do talhão.

A quinta etapa (**Retardo-TR**) teve o intuito de eliminar, pontos de baixa produtividade ocasionados pelo tempo de retardo no registro dos dados que apareceram na transição entre os talhões (Figura 4A). Nessa região de transição o retardo não foi corretamente configurado na máquina, fazendo com que a cana-de-açúcar colhida no ponto específico seja registrada vários metros à frente. Assim, os pontos próximos à essa faixa do carreador apresentavam valores nulos ou de baixa produtividade, inclusive se misturando com o problema do tempo de enchimento, logo após a passagem pelo carreador. No carreador, de fato, a produtividade deveria ser indicada como nula. Novamente utilizou-se a imagem do PlanetScope para validar a inconsistência do dado registrado e efetivamos a eliminação daqueles com produtividade baixa (0 a 6 $t.ha^{-1}$) (Figura 4B). Porém, essa eliminação de pontos não corrigiu o problema, apenas evitou a interpretação equivocada de que a bordadura dos talhões apresentava baixa produtividade; esse deslocamento sistemático no dado permaneceu, sendo que o correto seria ajustar o tempo de retardo, realocando todo o conjunto de dados a partir de um tempo calculado empiricamente (Michelan *et al*., 2007).

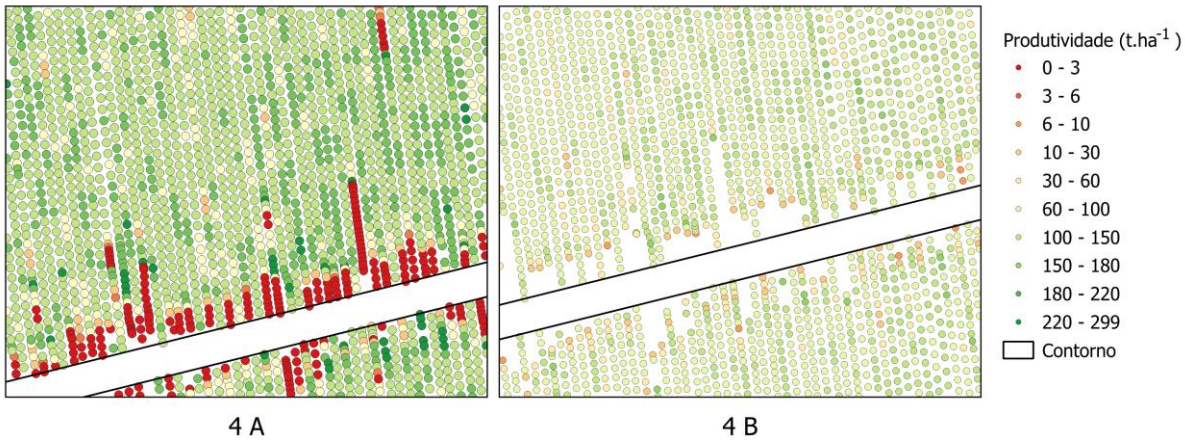


FIGURA 4. Recorte de uma parte da área para exemplificar o erro registrado devido ao tempo de retardo - A e dado corrigido - B.

A sexta etapa (**Pontos individuais discrepantes - PID**) foi uma análise visual dos padrões espaciais de produtividade. Valores de 0 $t.ha^{-1}$ e >220 $t.ha^{-1}$ que se apresentavam isolados entre outros valores de produtividade (Figura 5A) indicam incoerência, por conta de ruídos advindos de pontos muito altos ou muito baixos de produtividade encontrados nas fileiras de cana-de-açúcar (Maldaner, 2017). Notamos ainda um padrão consistente de baixa produtividade em espaço moderado, seguida de um único registro de altíssima produtividade (>220 $t.ha^{-1}$). Uma indicação de inconsistência de registro, provavelmente ocasionada pela operação da máquina: a colhedora paralisa o elevador para aguardar

o transbordo (pontos de baixa produtividade registrados), acumulando material no bojo da máquina; transferindo todo o material de uma só vez (pontos de alta produtividade na sequência) (Figura 5B). Neste caso, eliminamos apenas o valor extremo superior (>220 $t.ha^{-1}$) por se tratar de um padrão singular e improvável, enquanto os valores baixos podem ser verídicos, ocasionados por falhas de brotação, por exemplo. A sétima etapa (**Refino - R**) foi uma última avaliação geral dos dados, removendo inconformidades, tais como: registros de linha duplicados indicando repasses de linhas (Figura 5C), pontos extremos isolados que não foram removidos na sexta etapa, pontos de entrada de talhões com baixa produtividade discrepantes da região em que se encontravam (Figura 5D).

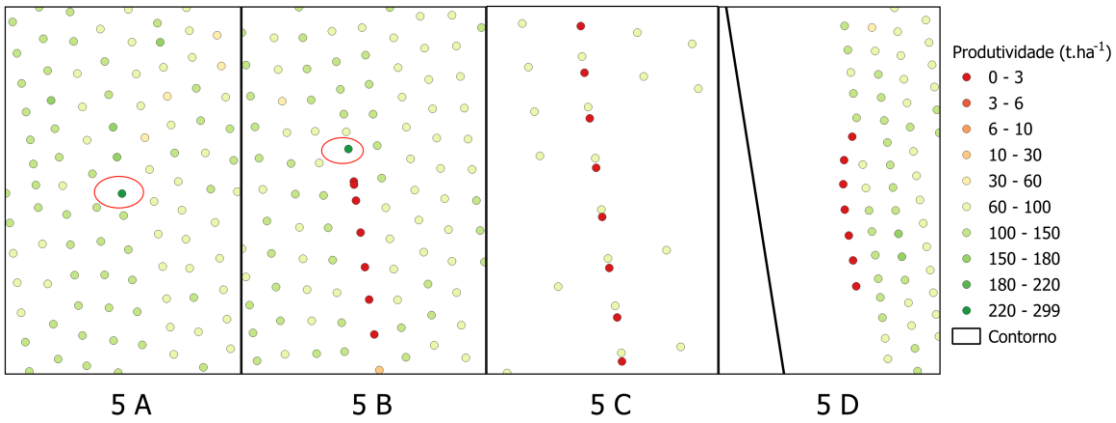


Figura 5. Recorte de uma parte da área para exemplificar os dados inconsistentes: 5A- valor extremo isolado; 5B-valor extremamente alto após sequência de baixa produtividade; 5C- repasse de linha; 5D entradas de linha de corte.

Os dados em diferentes etapas da filtragem foram interpolados pelo método do inverso do quadrado da distância para construção dos mapas de produtividades, destacando alguns efeito de interesse. Eles foram comparados visualmente com o índice de vegetação NDVI calculado pela imagen do PlanetScope, uma semana antes da colheita. Todos os procedimentos de visualização, correção e remoção de dados foram realizados com o software Qgis® versão 3.32.1, bem como a produção dos mapas de produtividade interpolados.

RESULTADOS E DISCUSSÃO

Devido à colheita de cana-de-açúcar ocorrer em cada linha individualmente, o monitor de produtividade registra muitos pontos; o conjunto original de dados para 102 ha continha aproximadamente 470 mil pontos (Tabela 1), resultando em ~4.600 pontos por hectare. Na segunda etapa de filtragem (LC) foi possível observar uma sutil diferença na estatística da produtividade; entretanto, melhora mais significativa foi observada com a eliminação dos valores extremos (VD). Após essa etapa houve convergência dos indicadores estatísticos da produtividade a um patamar razoável em torno de 89,0 $t.ha^{-1}$. Após a correção do tempo de enchimento (TE), houve uma estabilização das estatísticas do conjunto de dados para os valores de produtividade, desvio padrão e coeficiente de variação. Foi nesta etapa que ocorreu uma maior redução de pontos (N - remoção de 14000), mas mesmo assim representando apenas 5,5% do total de pontos.

TABELA 1. Estatística descritiva do conjunto de dados de produtividade após cada etapa da filtragem.

Etapa	N°	Pontos restantes	Média	Mediana	Mínimo	Máximo	Desvio Padrão	Coeficiente de Variação (%)
DB	469402	100%	97,81	86,89	0,0	693506,88	1312,52	13,41
Et.1 P	460254	98	97,81	86,89	0,0	693506,88	1312,52	13,41
Et. 2 LC	460254	98	99,85	89,03	0,0	693506,88	1330,74	13,32
Et. 3VD	457801	97,5	86,55	88,85	0,0	299,43	34,29	0,39
Et. 4 TE	443801	94,5	89,22	89,80	0,0	299,43	31,21	0,34
Et. 5 TR	441268	93,9	89,44	89,90	0,0	299,07	30,27	0,33
Et. 6 PID	440187	93,6	89,34	89,88	0,0	299,07	29,85	0,33
Et. 7 R	439695	93,3	89,39	89,90	0,0	299,07	29,67	0,33

Legenda. 1: Et.: Etapa; N°= Número de pontos; DB= Dados brutos (iniciais) P= Posicionamento (etapa 1); LC= Largura de corte (etapa 2); VD= Valores discrepantes (etapa 3); TE= Tempo de enchimento (etapa 4); TR= Tempo de retardo (etapa 5); PID= Pontos individuais discrepantes (etapa 6); R=Refino (etapa 7).

A análise dos resultados por etapa da limpeza mostra o efeito das etapas. É possível notar que os mapas construídos após a quinta etapa (TR) e a última (R) são praticamente idênticos (Figuras 6A e 6B). Desse modo, constatamos que as últimas duas etapas, apesar de remover pequenos erros locais nos dados, não incrementa a disposição espacial da produtividade de cana-de-açúcar. A interpolação dos dados de produtividade pelo método do inverso do quadrado da distância auxiliou na visualização da variação da produtividade dentro dos talhões, onde podemos constatar a diferenças entre as regiões com cultivares distintas, e pequenas variações ao longo da área. Esse mesmo comportamento é visualizado no mapa de NDVI o qual também apresenta essas variações (Figura 6C) podendo relacionar os valores do índice e a produtividade da cana-de-açúcar nos talhões.

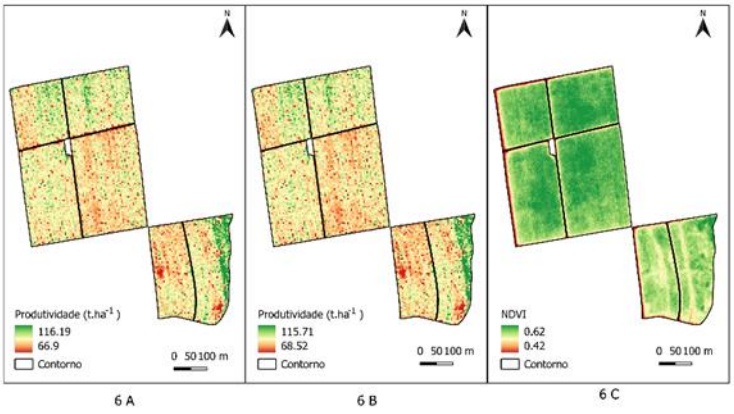


FIGURA 6. Mapas interpolados de produtividade e mapa do NDVI. 6A - interpolada após etapa 5; 6B - interpolada após etapa 7.

CONCLUSÃO

Os registros de monitores de colheita de cana-de-açúcar requerem pré-tratamento dos dados para produção de mapas de produtividade com qualidade, especialmente para verificação de erros de configuração do monitor e ocasionados pelo procedimento operacional do conjunto de colheita (colhedora + transbordo), além da eliminação de dados extremos fora da realidade. Estabelecer uma rotina mínima de verificação e edição de dados é importante para a disseminação do correto uso da informação gerada por monitores de colheita, evitando, assim, interpretações equivocadas, como a falsa constatação de baixa produtividade na bordadura dos canaviais. Recomenda-se especial atenção as filtragens de erros de configuração do monitor como a largura da faixa, dos valores extremamente altos e dos erros de tempo de enchimento e retardo.

AGRADECIMENTOS

A Fundação de Amparo à Pesquisa do estado de São Paulo (FAPESP), processo n°2022/03160-8, pela concessão de auxílio à pesquisa ao último autor.

REFERÊNCIAS

ARSLAN, S.; COLVIN, T. S. Grain yield mapping: yield sensing, yield reconstruction, and errors. **Precision Agriculture** v.3, p.135-154, 2002.

BRAMLEY, R.; TRENGOVE, S. Precision agriculture in Australia: present status and recent developments. **Engenharia Agrícola**, Jaboticabal, v.33, n.3, p.575-588, 2013.

DEERE, J. Colhedora de cana: Cane Advisor. Disponível em: https://www.deere.com.br/pt/colheitadeiras/colhedora-de-cana/cane-advisor/ . Acesso em: 10, janeiro de 2024.

GREGO, C. R.; ARAUJO, L. S.; VICENTE, L. E.; NOGUEIRA, S. F.; MAGALHÃES, P. S. G.; VICENTE, A. K.; BRANCALIÃO, S. R.; VICTORIA, D. C.; BOLFE, E. L. **Agricultura de precisão em cana-de-açúcar**. In: BERNARDI, A. C. de C.; NAIME, J. de M.; RESENDE, A. V. de; BASSOI, L. H.; INAMASU, R. Y. **Agricultura de precisão:** resultados de um novo olhar. Brasília, DF: Embrapa, 2014. p. 442-457.

LIU, R. et al. Development and application experiments of a grain yield monitoring system. **Computers and Electronics in Agriculture**, v. 195.

MAGALHÃES, P. S. G.; CERRI, D. G. Yield Monitoring of Sugar Cane. **Biosystems Engineering**, v. 96, p. 1-6, 2007.

MALDANER, L. F.; MOLIN, J. P.; SPEKKEN, M. Methodology to filter out outliers in high spatial density data to improve maps reliability. **Scientia Agricola**, v. 79, p. e20200178, 2021.

MENEGATTI, L. A. A; MOLIN, J. P. Remoção de erros em mapas de produtividade via filtragem de dados brutos. **Revista Brasileira de Engenharia Agrícola e Ambienta**l, v. 8, p. 126-134, 2004.

MICHELAN, R., SOUZA, E. G., URIBE-OPAZO, M. A. Determinação e remoção do tempo de atraso em mapas de colheita de milho. **Acta Sci. Agron,** v. 29, n. 2, p. 147-155, 2007

MOLIN, J. P.; AMARAL, L.R.; COLAÇO, A.F. **Agricultura de precisão.** Piracicaba: Escola Superior de Agricultura Luiz de Queiroz, 2001. p.83. Agricultura de precisão. ed 1. São Paulo: Oficina de Textos, 2015. p 224.

VISÃO COMPUTACIONAL E APRENDIZADO DE MÁQUINA PARA A QUANTIFICAÇÃO DE FERRUGEM (Hemileia vastatrix) NA CULTURA DO CAFEEIRO

Marisa Silveira Almeida Renaud Faulin [1]; Lucas de Brito Silva [2]; Álvaro Leandro Cavalcante Carneiro [2]; Gustavo Di Chiacchio Faulin [1]

[1]Docente. Av. Fundação Shunji Nishimura, 605, Pompeia, SP. Fatec Pompeia Shunji Nishimura;
[2]Tecnólogo. Av. Fundação Shunji Nishimura, 605, Pompeia, SP. Fatec Pompeia Shunji Nishimura

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Atualmente são gastos bilhões de reais no agronegócio mundial para o controle de doenças e pragas. Neste sentido, técnicas de manejo integrado de pragas e doenças, juntamente a evolução de algoritmos, técnicas de visão computacional e aprendizado de máquina, estão sendo utilizadas de modo a contribuir neste cenário. Dessa forma, o objetivo do presente trabalho foi desenvolver um algoritmo para quantificar a severidade dos sintomas da ferrugem (Hemileia vastatrix) nas folhas de cafeeiro (Coffea arabica). Para isso foram utilizadas imagens digitais obtidas por um smartphone com um aplicativo que sirva de interface gráfica para o usuário. Para tal fim, foram utilizadas a linguagem de programação Python, a biblioteca OpenCV e o algoritmo k-means (K-médias). Para a validação do algoritmo desenvolvido, chamado de Disease Quantify (DQ), foi realizada a quantificação da severidade de doença por três métodos: o algoritmo de quantificação RGB, o algoritmo de quantificação DQ e o software AFSoft. Foi realizado posteriormente a análise de variância. Quanto aos resultados, pôde-se observar que não houve diferença significativa ao nível de 5% entre os métodos, assim o algoritmo desenvolvido (DQ) foi eficiente em quantificar a severidade em folhas de cafeeiro.

PALAVRAS-CHAVE: fitopatologia; aplicação móvel; análise de agrupamento

ABSTRACT

Billions of Brazilian reais are currently spent in the global agribusiness sector for the control of diseases and pests. In this context, integrated pest and disease management techniques, alongside the evolution of algorithms, computational vision techniques, and machine learning, are being used to contribute to this scenario. Thus, the aim of the present study was to develop an algorithm to quantify the severity of rust symptoms (Hemileia vastatrix) on coffee leaves (Coffea arabica). For this purpose, digital images obtained by a smartphone with an application serving as a graphical interface for the user were used. The Python programming language, the OpenCV library, and the k-means algorithm. To validate the developed algorithm, called Disease Quantify (DQ), disease severity was quantified using three methods: the RGB quantification algorithm, the DQ quantification algorithm and the AFSoft software. Subsequently, an analysis of variance was performed. Regarding the results, statistical tests revealed that there was no significant difference at the 5% level between the methods, thus the developed algorithm (DQ) was efficient in quantifying the severity on coffee leaves.

KEYWORDS: ;

INTRODUÇÃO

A Ferrugem do cafeeiro causada pelo fungo Hemileia vastatrix ocorre desde 1869 na África Oriental. A doença gera fortes danos, como a desfolha precoce dos pés do cafeeiro e quedas de produção nos anos seguintes. Há relatos de queda de produção na ordem de 34% (MATIELLO, J. B. et al., 2010). Para os tratamentos fúngicos, de maneira geral, é necessária a quantificação da severidade de doenças

que é realizado pelos pragueiros de maneira subjetiva e manual, utilizando escalas diagramáticas e chaves descritivas.

O uso de métodos de análise de imagens com visão computacional e aprendizado de máquina podem auxiliar na problemática da quantificação de doenças de plantas. Dentre esses métodos, o k-means, é um método não supervisionado que realiza agrupamento de dados de um dataset de acordo com as suas similaridades e em quantidades desejadas. Ou seja, o algoritmo gera um ponto/dado inicial randômico como centróide para um determinado cluster e depois tenta atribuir os demais dados do dataset aos clusters de acordo com a sua proximidade. Para isso, o algoritmo usa técnicas de distância euclidiana (MAHMUD; RAHMAN; AKHTAR; 2012). Vale ressaltar que os pontos centróides são atualizados conforme as classificações que são feitas no algoritmo e param de atualizar quando o algoritmo cumpre seu objetivo, há poucas interações dos dados com diferentes clusters ou através de um número fixo de interações (DUNHAM, 2006; DEVI; RATHAMANI, 2020).

Existem alguns softwares para análise e quantificação de doenças em plantas. O software AFSoft desenvolvido pela EMBRAPA é utilizado para essa análise e contempla a função de mapear e quantificar as doenças que atacam as folhas das plantas com o uso de imagens e de Multilayer Perceptron (MLP), uma rede neural supervisionada que tenta simular o cérebro humano (SILVA; JORGE; 2009). Embora eficaz, sua abordagem necessita de considerável esforço computacional e uma etapa de treinamento prévia com intervenção humana. Contrariamente, o desenvolvimento do DQ visa oferecer uma alternativa mais eficiente, empregando aprendizado não supervisionado para automatizar completamente o processo de detecção de doenças, eliminando a necessidade de treinamento prévio. Isso representa um avanço significativo, ao simplificar o diagnóstico de doenças em plantas.

OBJETIVOS

O objetivo deste trabalho foi desenvolver um algoritmo capaz de quantificar automaticamente a severidade dos sintomas de ferrugem em folhas da cultura do cafeeiro.

MATERIAL E MÉTODOS

Para o desenvolvimento do algoritmo denominado Disease Quantify (DQ) foram coletadas 287 folhas de cafeeiro com sintomas da ferrugem. Estas amostras foram retiradas manualmente e aleatoriamente do cafezal localizado no campus da FATEC Pompéia - Shunji Nishimura (-22.1098646, -50.1969503). Posteriormente, fotos das folhas foram capturadas em laboratório com um fundo branco, usando a câmera de um smartphone (Xiaomi Mi Note 3) no sistema de cores RGB, que é o padrão de cores adotado por máquinas fotográficas digitais (MESQUITA et al., 2010), em uma resolução de 4000 x 2250 pixels (px).

Como pré-requisito para que houvesse a quantificação de severidade, foi necessário utilizar a linguagem Python, com a biblioteca OpenCV, que é especializada para o campo de visão computacional. Para realizar a quantificação, a resolução original da imagem foi diminuída em 3,125 vezes, passando de 4000 x 250 pixels para 1280 x 720 pixels. Essa redução, além de não afetar os resultados, também reduz o tempo de processamento do algoritmo.

Depois, foram empregadas técnicas de segmentação pelo método GrabCut com o uso de cinco interações.

Por fim, foi feito uma conversão de sistema de cores de RGB para HSV, de modo que fosse utilizado apenas a camada valor do sistema HSV, o qual se refere ao brilho total das cores e representa a parte acromática de uma imagem em RGB (SCHNEIDER; BELLON; ARAKI; 2003).

Sua fórmula pode ser representada pela equação do valor, demonstrada na Eq. 1:

$$Valor = \max(R', G', B)$$

onde,

R' = valor da banda do vermelho / 255;

G' = valor da banda do verde / 255;

B' = valor da banda do azul / 255.

Concernente a quantificação de severidade de doença na folha, após a aplicação dos filtros de pré-tratamento, com o auxílio da biblioteca SKlearn, foi utilizado o método de machine learning k-means, sendo este testado com 3, 4 e 5 clusters. Seu pseudocódigo foi representado por Dunham et al. (2006).

Os números que representam a imagem, o fundo, a doença e a área da folha somada à doença, assim como a porcentagem de severidade da doença foram calculados a partir da seguinte fórmula (Eq. 2):

$$SD = \frac{d \cdot 100}{Adf}$$

onde SD representa a severidade da doença, d a área afetada pela doença e Adf a área da folha somada à doença.

Após o desenvolvimento do algoritmo DQ, foi realizada sua validação. Para isso foi realizada a quantificação da severidade de ferrugem nas folhas de cafeeiro em outros dois métodos: o algoritmo de quantificação RGB e o software AFSoft.

Para comprovar a porcentagem de severidade utilizando a ferramenta AFSoft, foi adotado um processo sistemático após a pré-seleção das imagens destinadas aos testes. Inicialmente, procedeu-se à categorização manual dos elementos da imagem em três classes distintas: fundo, folha e doença. Seguiu-se a binarização da imagem (Figura 1). Posteriormente, foi necessário estabelecer uma rede neural. Finalmente, as imagens selecionadas - ou um conjunto delas - foram submetidas ao processamento.

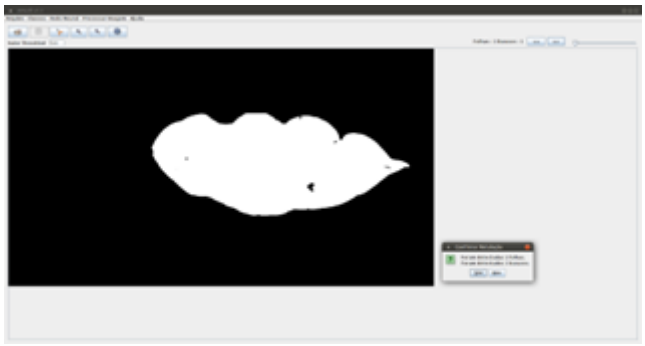


FIGURA 1. Imagem no processo de binarização.

Após a obtenção dos resultados, conduziu-se o teste estatístico de Kolmogorov-Smirnov, para determinar se os dados são definidos como normais e análise de variância (ANOVA) nos três métodos - DQ, RGB e AFSoft - visando avaliar a existência de diferenças significativas nas áreas afetadas pela doença identificadas por cada método.

RESULTADOS E DISCUSSÃO

Destaca-se dentre a realização dos testes computacionais, primeiramente, o uso da técnica GrabCut, que foi muito importante na etapa de segmentação da imagem, pois foi possível que apenas a folha do cafeeiro fosse capturada, separando assim a folha de café doente do fundo da imagem, como é possível verificar na Figura 2. Esse método também foi proposto por Rother, Kolmogorov e Blake (2004), em que, apenas a área de interesse/objeto em primeiro plano fosse capturada e os demais pixels fossem descartados.



FIGURA 2. Resultado do GrabCut.

Outro teste foi realizado com o AFSoft e descartou o fundo da imagem automaticamente, quando na cor preta, o que expressa apenas o valor que representa a folha e a doença. A ferramenta devolve como resultado, uma tabela que contém as porcentagens de folha e de doença assim como apresentado na imagem pintada (Figura 3).



FIGURA 3. Imagem de resultado feita pela ferramenta AFSoft.

Dessa forma, os melhores resultados foram obtidos ao utilizar da combinação entre duas técnicas, sendo: i) GrabCut com cinco interações, visto que com esse número de interações foi possível obter resultados claros de segmentação (CHEN et al., 2008) e ii) k-means com cinco clusters, no sistema de cores HSV com o canal valor.

Em relação à severidade de ferrugem nas folhas, observou-se maior eficiência do algoritmo DQ em folhas que ele quantificava com severidades entre 25 e 50% com a definição de 3 clusters, visto que quando a doença era a terceira cor de destaque, o seu agrupamento era maior. Todavia, com menores sintomas da doença, 5 clusters obtiveram um resultado mais assertivo, visto que os sintomas das doenças eram menores e precisavam de um número maior de agrupamentos para serem detectados.

Com os testes estatísticos de Kolmogorov-Smirnov resultando em um p-valor = 0,0169, foi possível determinar os dados como normais. Depois foi realizada análise de variância (Tabela 1) com os métodos RGB, Camada Valor (Disease Quantify - DQ) e AFSoft. Assim, com o p-valor = 0,399 conclui-se que não há diferença significativa entre os métodos avaliativos da severidade da ferrugem cafeeira, considerando um nível de significância de 5%.

Além disso, pôde-se observar, também, que a partir da realização de uma estimativa, através de um intervalo de confiança (gráfico 1), o AFSoft obteve valores discrepantes, todavia, ainda sem diferença significativa, como apresenta o teste de ANOVA (Tabela 1). Os limites superior e inferior do AFSoft, no gráfico de intervalo de confiança, foram, respectivamente, de 9,027 e um de 4,8999.

TABELA 1. Resultado da análise de variância (ANOVA).

	Graus de Liberdade	Soma de Quadrados	Quadrado Médio	Estatística F	p-valor
Fator	2	39,68028	19,84014		
Resíduos	57	1.210,654445	21,23955167	0,934112938	0,398865415

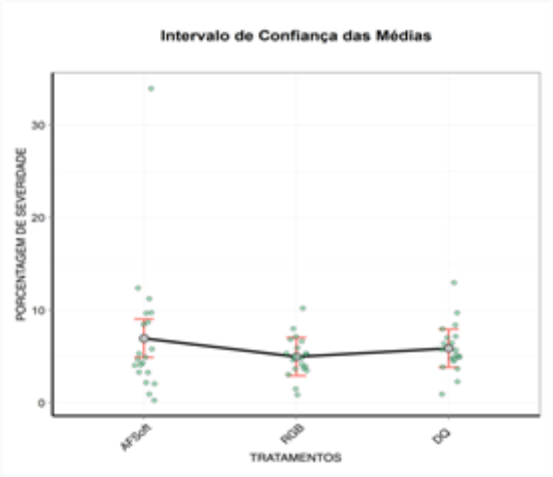


GRÁFICO 1. Intervalo de confiança das médias dos métodos AFSoft, RGB e Valor.

Mesmo com o resultado da ANOVA não demonstrando uma diferença estatística com outros algoritmos, inclusive o AFSoft, é possível sugerir que alguns pontos de melhoria no algoritmo desenvolvido neste trabalho. Entre eles destaca-se o uso de uma limiarização mais criteriosa, o uso de canais de cor que permitam maior assertividade e clusters dinâmicos para o algoritmo de segmentação (DUTTA; TALUKDAR; BORA; 2022).

CONCLUSÃO

O algoritmo desenvolvido Disease Quantify (DQ) foi capaz de manipular as imagens, utilizar técnicas de visão computacional e machine learning com eficiência e assertividade na estimativa automática da severidade da doença causada por Hemileia vastatrix na folha de cafeeiro (Coffea arabica).

AGRADECIMENTOS

Á Fatec de Pompeia "Shunji Nishimura" e a Fundação Shunji Nishimura de Tecnologia.

REFERÊNCIAS

CHEN, Daniel; CHEN, Benden; MAMINC, George; FOOKES, Clinton; SRIDHARAN, Sridha. Improved GrabCut Segmentation via GMM Optimisation. **Digital Image Computing: Techniques and Applications**, Canberra, ano 2008, p. 39-45, 1 dez. 2008. DOI 10.1109/DICTA.2008.68. Disponível em: https://ieeexplore.ieee.org/document/4699997. Acesso em: 30 abr. 2024.

CUNHA, Rodrigo Luz da; POZZA, Edson Ampélio; DIAS, Waldir Pereira; BARRETTI, Patrícia Baston. Desenvolvimento e validação de uma escala diagramática para avaliar a severidade da ferrugem (Hemileia vastatrix) do cafeeiro. **Simpósio de Pesquisa dos Cafés do Brasil**, Vitória, v. 2, 2002. Disponível em: http://www.sbicafe.ufv.br/handle/123456789/1204. Acesso em: 30 abr. 2024.

MESQUITA, Deives; MENEGHELLO, Géri Eduardo; TILLMANN, Maria Angela; OLIVEIRA, Lucas. Segmentação de Imagens com Fundo Azul Utilizando a Multiplicação dos Canais HSV para a Identificação de Sementes. **Encontro de Pós-Graduação (ENPOS)**, Pelotas, 2010. Disponível em: https://www2.ufpel.edu.br/cic/2010/cd/pdf/CE/CE_01519.pdf. Acesso em: 30 abr. 2024.

DEVI, P. Kanjana; RATHAMANI,. Image Segmentation K-Means Clustering Algorithm for Fruit Disease Detection Image Processing. **International Conference on Electronics, Communication and Aerospace Technology (ICECA)**, Coimbatore, ano 2020, p. 861-865, 28 dez. 2020. DOI 10.1109/ICECA49313.2020.9297462. Disponível em: https://ieeexplore.ieee.org/document/9297462. Acesso em: 30 abr. 2024.

DOS SANTOS FRANCISCO, V. L. F. et al. ESTRUTURA PRODUTIVA DA CAFEICULTURA PAULISTA1. **Projeto Levantamento Censitário de Unidades de Produção Agrícola do Estado de São Paulo - Projeto LUPA**, 2008. Disponível em: https://www.cati.sp.gov.br/projetolupa/estudos_lupa/EstruturaProdutivaCafeicultura.pdf. Acesso em: 30 abr. 2024.

DUNHAM, Margaret H. **Data mining: Introductory and advanced topics**. 1. ed. Pearson Education India, 2007. 328 p. ISBN 8177587854.

DUTTA, Kishore; TALUKDAR, Dhritiman; BORA, Siddhartha S. Segmentation of unhealthy leaves in cruciferous crops for early disease detection using vegetative indices and Otsu thresholding of aerial images. **Measurement**, [S. l.], v. 189, p. 110748, 20 jan. 2022. DOI 10.1016/j.measurement.2021.110478. Disponível em: https://www.sciencedirect.com/science/article/abs/pii/S0263224121013622. Acesso em: 30 abr. 2024.

KASS, Michael; WITKIN, Andrew; TERZOPOULOS, Demetri. Snakes: Active Contour Models. **International Journal of Computer Vision**, Boston, v. 1, p. 321-331, 1 jan. 1988. DOI 10.1007/BF00133570. Disponível em: https://link.springer.com/article/10.1007/BF00133570. Acesso em: 30 abr. 2024.

MAHMUD, Sohrab; RAHMAN, Mohammed Mostafizer; AKHTAR, Mohammed Nasim. Improvement of K-means clustering algorithm with better initial centroids based on weighted average. **International Conference on Electrical and Computer Engineering**, Dhaka, Bangladesh, n. 7, p. 647-650, 20 dez. 2012. DOI 10.1109/ICECE.2012.6471633. Disponível em: https://ieeexplore.ieee.org/document/6471633. Acesso em: 30 abr. 2024.

MATIELLO, J. B.; SANTINATO, R.; GARCIA, A. W. R.; ALMEIDA, S. R.; FERNANDES, D. R. **Cultura do Café no Brasil: Manual de Recomendações**. Rio de Janeiro-RJ, Varginha-MG: Fundação Procafé, 2010. 548 p.

ROTHER, Carsten; KOLMOGOROV, Vladimir; BLAKE, Andrew. GrabCut: interactive foreground extraction using iterated graph cuts. **ACM Transactions on Graphics**, New York, NY, v. 23, n. 3, p. 209-214, 1 ago. 2004. DOI 10.1145/1015706.1015720. Disponível em: https://dl.acm.org/doi/10.1145/1015706.1015720. Acesso em: 30 abr. 2024.

SCHNEIDER, Mario Jorge; BELLON, Olga Regina Pereira; ARAKI, Hideo. Experimentos em fusão de imagens de alta resolução. **Boletim de Ciências Geodésicas**, v. 9, n. 1, p. 75-88, 2003. Disponível em: https://revistas.ufpr.br/bcg/article/view/1428. Acesso em: 30 abr. 2024.

SILVA, D. J. da C. B.; JORGE, L. A. de C. AFsoft ? software para análise foliar. **Anais da I Jornada Científica - Embrapa São Carlos**. São Carlos, SP. p. 53, 29 out. 2009. Disponível em: https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/579344/1/Proci09.00298.pdf. Acesso em: 30 abr. 2024.

WANG, Zhaobin; LV, Yongke; WU, Runliang; ZHANG , Yaonan. Review of GrabCut in Image Processing. **Mathematics**, [S. l.], ano 8, v. 11, 21 abr. 2023. Mathematical Methods for Pattern Recognition, p. 1965. DOI 10.3390/math11081965. Disponível em: https://www.mdpi.com/2227-7390/11/8/1965. Acesso em: 30 abr. 2024.

INFLUÊNCIA DA "CAUDA DO PATAMAR" NO AJUSTE SEMIVARIOGRÁFICO E NAS ESTIMATIVAS DO ÍNDICE SMP POR KRIGAGEM ORDINÁRIA PONTUAL

Frederico Ravazi de Castro [1]; Gilberto Galle [1]; Leonardo Mello Foletto [1]; Lucas Cagliari Grando [1]; Lúcio De Paula Amaral [2]; Luise Jardim Pedó [1]; Maria Eduarda Hitz [1]
[1]Mestrando PPGAP. Santa Maria - RS. Unversidade Federal de Santa Maria; [2]Docente. Santa Maria - RS. Unversidade Federal de Santa Maria

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
Na análise geoestatística, o ajuste de semivariogramas é uma operação essencial e crítica, pois interfere diretamente nas estimativas realizadas por krigagem ordinária pontual. O semivariograma define a autocorrelação ou dependência espacial/temporal, cujo comportamento pode ser afetado por dados de comportamento aleatório, aqueles separados por longas distâncias, quando realizados ajustes semivariográficos, nos quais o patamar apresenta "caudas longas". O objetivo do trabalho foi testar o efeito de semivariogramas, ajustados com diferentes tamanhos de "cauda do patamar", nas estimativas de valores do Índice SMP, realizar correlação de mapas e verificar a tendência/dispersão de valores, entre o ajuste de referência e os demais ajustes semivariográficos realizados, configurados a partir da máxima distância de análise (DA). O Índice SMP foi obtido em uma área de pesquisa on farm, com 122 pontos amostrais, na Fazenda Mata Grande, Vila Nova do Sul - RS, em 2022. Foi utilizado o programa GS+, no qual os ajustes semivariográficos foram configurados com a máxima DA de 961,19 m, e os percentuais 75, 60, 50, 20% DA e um ajuste de referência (330 m) definido pelo usuário. Foram utilizadas análise de estatística descritiva, qualidade dos ajustes semivariográficos e validação cruzada, correlação de Spearman, RMSE e BIAS. Todas as análises mostraram que patamares com "caudas longas" incrementaram efeito aleatório nas estimativas.

PALAVRAS-CHAVE: Análise Geoestatística; Efeito Aleatório em Estimativas; Correção de Solos

ABSTRACT
In geostatistical analysis, the adjustment of semivariograms is an essential and critical operation, as it directly interferes with the estimates made by ordinary kriging. The semivariogram defines the autocorrelation or spatial/temporal dependence, whose behavior can be affected by data with random behavior, those separated by long distances, when semivariographic adjustments are made, in which the sill presents "long tails". The objective of the work was to test the effect of semivariograms, adjusted with different sizes of "sill tail", on the SMP Index value estimates, perform map correlation and check the trend/dispersion of values, between the reference adjustment and the other semivariographic adjustments performed, configured based on the maximum analysis distance (DA). The SMP Index was obtained in an on-farm research area, with 122 sampling points, at Fazenda Mata Grande, Vila Nova do Sul - RS, in 2022. The GS+ program was used, in which the semivariographic adjustments were configured with the maximum DA of 961.19 m, and the percentages 75, 60, 50, 20% DA and a reference setting (330 m) defined by the user. Descriptive statistics analysis, quality of semivariographic adjustments and cross validation, Spearman correlation, RMSE and BIAS were used. All analyzes showed that sill with "long tails" increased the random effect in the estimates.

KEYWORDS: ;

INTRODUÇÃO

A Geoestatística desempenha um papel crucial na Agricultura de Precisão, pois permite a compreensão da variabilidade espacial/temporal dos atributos (solo, planta, clima, outros), sendo utilizada na geração de mapas, que servem como ferramentas de apoio ao processo de tomada de decisão (GREGO et al., 2014). Porém, são necessários cuidados e atenção por parte do usuário durante o procedimento de ajuste dos semivariogramas para as variáveis/atributos de interesse. O ajuste dos semivariogramas impactam nas estimativas realizadas pela krigagem ordinária pontual, pois gera um vetor de pesos que pondera os valores da variável de interesse, mensurados nos pontos amostrais, e que serão utilizados para realizar estimativa em um ponto qualquer, não amostrado, na área de interesse, conforme demonstrado por Santos et al., (2023) para valores de pHH2O do solo.

Neste aspecto da acidez, os solos do Estado do Rio Grande do Sul geralmente são muito ácidos, sendo sua correção calibrada pelo Índice SMP. Originalmente proposto por Shoemaker et al. (1961), o método pH-SMP faz análise e correção de acidez do solo, corresponde ao pH de equilíbrio obtido na suspensão entre o solo e a solução-tampão SMP, cujo valor é utilizado para indicar a quantidade de calcário necessária para elevar o pH do solo ao valor desejado (necessidade de calagem). Atualmente, a técnica utilizada pelo manual de calagem e adubação é denominada Tampão Santa Maria (TSM), sendo uma adaptação da proposta originalmente apresentada, com a vantagem de não conter substâncias potencialmente tóxicas (TOLEDO, 2011).

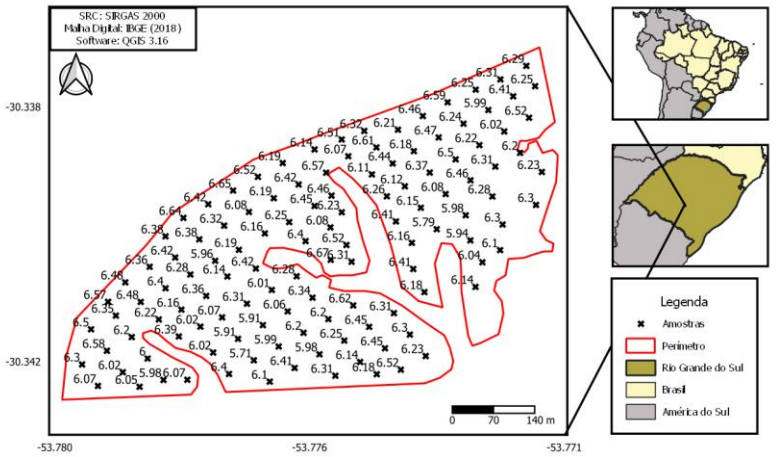
OBJETIVOS

Neste contexto, o objetivo deste trabalho foi testar o efeito de semivariogramas ajustados com diferentes tamanhos de "cauda do patamar" nas estimativas de valores do Índice SMP, obtidos em uma área de pesquisa agrícola on farm, realizar correlação de mapas e verificar a tendência/dispersão de valores entre o ajuste de referência e os demais ajustes semivariográficos realizados, e poder auxiliar na orientação de usuários de geoestatística.

MATERIAL E MÉTODOS

O trabalho foi desenvolvido na Fazenda Mata Grande, no município de Vila Nova do Sul, localizado na porção central do Estado do Rio Grande do Sul (Latitude 30°20'24.7"S, Longitude 53°46'34.6"W) (Figura 1). O município possui clima subtropical, conforme classificação climática de Köppen (WREGE et al., 2012) e com tipo de solo Luvissolos Crômicos Órticos típicos originados de xisto (STRECK et al, 2018). A área de estudo foi um talhão agrícola comercial utilizado para pesquisas on farm pela empresa Base Precisão na Agricultura, contendo 31,7 hectares, sendo utilizado para cultivo de soja (Glycine max L) com rotação de aveia branca (Avena sativa L.).

Figura 1. Localização da área de estudo, Fazenda Mata Grande, Vila Nova do Sul-RS, com detalhes do grid amostral para coleta de solo com os valores do Índice SMP - dados ano 2022.



A coleta de amostras de solo para análise de fertilidade ocorreu entre os dias 19 e 21 de abril de 2022, sendo utilizada uma malha amostral de 122 pontos georreferenciados (densidade amostral de quatro amostras por hectare), na camada de 0 a 15 cm de profundidade. As amostras foram coletadas com quadriciclo instrumentado com amostrador automático de solo tipo sonda, coletando doze subamostras dentro de um raio de até 15 m do ponto georreferenciado, para representar cada amostra composta.

As análises de fertilidade e da granulometria do solo foram realizadas no Laboratório BaseLab, segundo o método de análise de solo do programa interlaboratorial de controle de qualidade de análise de solos ROLAS - Rede Oficial de Laboratórios de Análise de Solo e de Tecido Vegetal dos Estados do Rio Grande do Sul e de Santa Catarina, sendo expedidos os valores dos atributos via laudo, dentre os quais o Índice SMP foi selecionado para a realização deste trabalho. Com os dados do Índice SMP, juntamente com as coordenadas dos pontos amostrais, foi gerada uma planilha eletrônica, sendo exportada para o programa geoestatístico GS+ versão 7 - Gamma Design (ROBERTSON, 1998).

Precedendo a análise semivariográfica foi realizada a análise de estatística descritiva para os dados do Índice SMP, utilizando planilha eletrônica. No programa geoestatístico foram realizados os ajustes de semivariogramas isotrópicos a sentimento, procedimento no qual o usuário altera a distância de análise e o tamanho do lag, resultando em diferentes nuvens de dispersão de semivariância experimental, para a qual um semivariograma (1) teórico (modelo matemático) será ajustado e assim definidos os coeficientes do modelo e as estatísticas do ajuste (ZIMBACK, 2001; YAMAMOTO e LANDIM, 2013).

O semivariograma é dado por h=12N(h)i=1n(h)Z(xi)-Z(xi+h)2 (1)

Onde: h - é a semivariância estimada; 2N(h) - é o número de pares de valores medidos Z(xi)-Z(xi+h)2 separados por um vetor h.

Foram configuradas diferentes tamanhos para a distância de análise, eixo x do semivariograma, a fim de produzir diferentes tamanhos de "cauda do patamar". Primeiramente foi encontrada a maior distância de análise possível para o conjunto de dados (pontos amostrais) 961,19 m, produzindo a maior "cauda do patamar". Posteriormente, foram utilizados diferentes percentuais da maior distância de análise, sendo 75% (720,89 m), 60% (576,71 m), 50% (480,60 m), ajuste de referência (330,00 m) - considerado o ajuste adequado, e 20% (192,23 m). O tamanho do lag foi mantido fixo em todos os ajustes, sendo a menor distância entre dois pontos amostrais, considerando o conjunto de dados utilizado.

O ajuste de referência considerou, primeiramente, obter um semivariograma estruturado, que apresentasse valores de semivariância experimental dando suporte a passagem da linha de tendência

do semivariograma teórico a ser ajustado. Considerou-se que apresentasse também um ponto de formação do patamar bem definido, e posteriormente manteve se uma pequena porção do patamar, a fim de evitar excessiva contribuição de dados presente no campo aleatório, que geram mais incertezas nas estimativas obtidas por krigagem, a ser verificado nos mapas obtidos.

Para analisar a qualidade dos ajustes, o programa utiliza o teste da validação cruzada. Foram verificadas as estatísticas do ajuste da equação da reta, definida pela relação entre valores amostrados e estimados a partir de cada semivariograma teórico. Após a validação cruzada foram geradas as interpolações por krigagem ordinária pontual (ZIMBACK, 2001; YAMAMOTO e LANDIM, 2013), para gerar os mapas de variabilidade espacial do Índice SMP (estimativas em locais não amostrados) e mapas de desvio padrão (incerteza associada às estimativas), para cada ajuste de semivariograma (segundo os diferentes tamanhos de cauda do patamar). As imagens interpoladas foram salvas em arquivos de extensão .grd, com tamanho de pixel de 5x5 m, totalizando 12687 pixels em cada imagem, sendo importadas para o sistema de informações geográficas (SIG) Arc Map versão 10.8 - ESRI.

A krigagem ordinária pontual é dada por: Zx0=i=1niZ(xi) (2)

Onde: Zx0 - é o valor estimado em um local não amostrado; n - é o número de vizinhos;

i - é o peso associado ao valor obtido na posição xi e Z(xi) - é o valor de uma dada variável obtida por amostragem.

No SIG, as imagens interpoladas, para cada um dos ajustes semivariográficos realizados, foram convertidas para formato vetorial (Shapefile de feição pontual), onde o pixel foi convertido para ponto e o seu valor (Índice SMP estimado por krigagem) foi convertido para atributo do ponto, compondo a tabela de atributos. As tabelas de atributos de cada ajuste foram exportadas em arquivos de texto, para os dados serem organizados em planilha eletrônica e preparados para análise de correlação linear.

Antecedendo as análises de correlação, foram realizados testes de normalidade para as estimativas de Índice SMP obtidas em cada ajuste semivariográfico considerado, para definir que tipo de correlação utilizar, Pearson para dados normais ou Spearman para dados não-normais.

Para a comparação das estimativas do Índice SMP obtidas com o ajuste de referência com os demais ajustes, foram empregadas duas análises estatísticas, sendo RMSE (3) e BIAS (5) em valores absolutos e RMSE (4) e BIAS (6) em valores relativos.

A Raiz do Erro Quadrado Médio, do inglês Root Mean Square Error é dada por: RMSE = i=1nŷi-yi²n (3)

Onde: RMSE - Raiz do erro quadrado médio; n - o número de elementos; ŷi - é o valor estimado; yi - é o valor amostrado.O RMSE relativo em percentagem é dada por: RMSE (%)= i=1nŷi-yi²n?*100 (4)

Onde: RMSE - Raiz do erro quadrado médio; n - o número de elementos; ŷi - é o valor estimado; yi - é o valor amostrado; ? - é a média ponderada dos valores de referência.

O Bias é dado por: Bias= 1ni=1nŷi-yi (5)Onde: Bias - Medida de viés absoluto; n - o número de elementos; ŷi - é o valor estimado; yi - é o valor amostrado; ? - é a média dos valores de referência.

O Bias relativo em percentagem é dado por: Bias(%)= Bias?*100 (6)

Onde: Bias (%) - Medida de viés relativo; Bias - Medida de viés absoluto; ? - é a média dos valores de referência.

RESULTADOS E DISCUSSÃO

Foi realizada a análise estatística descritiva para os valores do Índice SMP obtidos nos 122 pontos amostrais (Tabela 1). Os valores do Índice SMP variaram de 5,71 a 6,67, sendo a média 6,26. Esses valores indicam que a área vem sendo manejada com aplicação de calcário para correção da acidez.

Tabela 1. Estatística descritiva para o Índice SMP obtido nos pontos amostrais na área de estudo, Fazenda Mata Grande, Vila Nova do Sul-RS - Ano 2022.

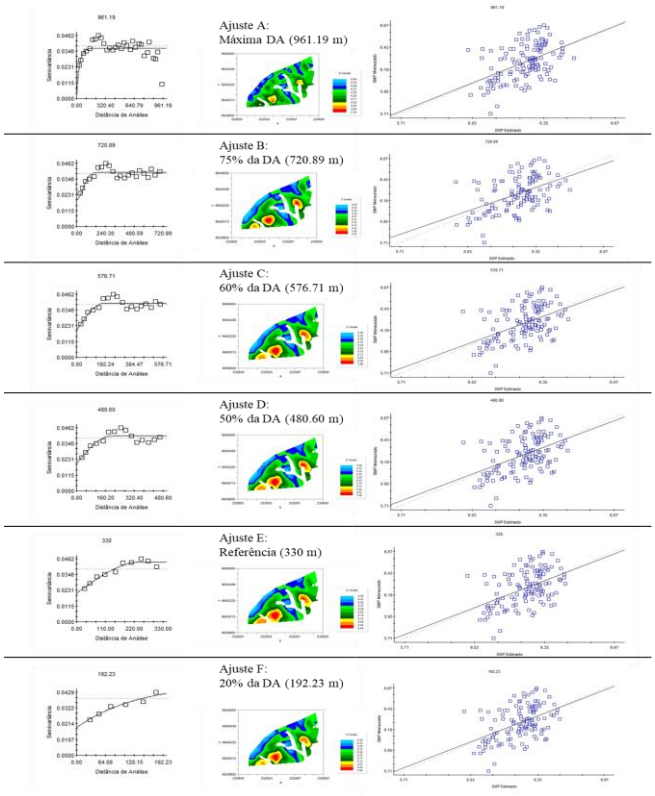
Variável	M	EPm	Md	Mo	Vmx	Vmn	I	S^2	S	A	Ct	CV%	NC (95.0%)
Índice SMP	6,26	0,02	6,27	6,31	6,67	5,71	0,96	0,039	0,196	-0,140	-0,413	3,14	0,035

Legenda - M: Média; EPm: Erro Padrão da média; Md: Mediana; Mo: Moda; Vmx: Valor máximo; Vmn: Valor mínimo; I: Intervalo; S^2: Variância dos dados; S: Desvio padrão; A: Assimetria; Ct: Curtose; CV%: Coeficiente de Variação (%); NC: Nível de confiança.

Foi observado que média, mediana e moda para o Índice SMP apresentaram valores próximos, sugerindo normalidade aos dados, e esta condição geralmente facilita o ajuste de semivariogramas, mesmo a normalidade dos dados não ser uma exigência para análise geoestatística. Também foi observado baixo coeficiente de variação, 3,14%, que indica haver baixa variabilidade nos dados.

Ao realizar a análise variográfica, e configurar a distância de análise para produzir diferentes tamanhos de "cauda do patamar", sendo a máxima distância de análise 961,19 m, e os diferentes percentuais de redução desta distância, sendo 75% (720,89 m), 60% (576,71 m), 50% (480,60 m), ajuste de referência (330,00 m) e 20% (192,23 m), foi observada a formação de semivariogramas estruturados por muitos valores de semivariâncias experimentais em cada forma de ajuste (Figura 2). Graficamente, foi possível observar a diferença de proporção entre as duas regiões que formam o semivariograma. A primeira é a região na qual os valores de semivariâncias experimentais aumentam com o aumento do passo ou lag, até o ponto de formação do patamar, chamada de campo estruturado espacialmente, na qual os dados possuem dependência espacial, é a região de contribuição (C). A segunda região é aquela onde o valor do patamar se estabiliza e se estende, formando a "cauda do patamar", é a região na qual os dados possuem comportamento aleatório (ZIMBACK, 2001).

Figura 2. Ajustes de semivariogramas e validação cruzada para o Índice SMP, conforme os diferentes tamanhos de "cauda do patamar" - máxima distância de análise 961,19 m (a), e suas reduções 75% (b), 60% (c), 50% (d), 20% (f), assim como um ajuste referência (e), utilizando 330m na distância de análise.*



* Na validação cruzada, a linha contínua representa os valores estimados, enquanto a linha pontilhada representa os valores amostrados.

Foram obtidos os coeficientes dos modelos espaciais (semivariograma teórico), ajustados aos semivariogramas experimentais, e as estatísticas para todos os ajustes semivariográficos realizados, bem como os coeficientes e estatísticas para a validação cruzada, ao relacionar valores amostrados e estimados (Tabela 2). Foi observada a predominância do modelo esférico, no ajuste de referência (330,00m), a 50 e 60% DA (480,60 e 576,71m, respectivamente). Já nas situações extremas, no ajuste com a máxima distância de análise (961,19m) e a 20% DA (192,23m) foi observado o modelo exponencial. O ajuste a 75% DA (576,71m) apresentou o modelo gaussiano, que aparentemente comportou-se como uma situação transitiva em relação ao comportamento das nuvens de valores de semivariâncias experimentais proporcionadas em cada ajuste.

Tabela 2. Coeficientes e estatísticas dos modelos obtidos no ajuste de semivariograma e validação cruzada, para o Índice SMP, conforme os diferentes tamanhos de "cauda do patamar" em função da distância de análise utilizada, Fazenda Mata Grande, Vila Nova do Sul-RS - Ano 2022.

	Ajuste do Semivariograma					
Distância de Análise (DA)	192,23m (20% DA)	330,00m (Referência)	480,60m (50% DA)	576,71m (60% DA)	720,89m (75% DA)	961,19m (Max DA)
Lag	32,04	32,04	32,04	32,04	32,04	32,04
Modelo	Exponencial	Esférico	Esférico	Esférico	Gaussiano	Exponencial
Efeito Pepita	0,01872	0,02084	0,01996	0,01971	0,01968	0,00270
Patamar	0,04914	0,04368	0,04002	0,03962	0,03946	0,03680

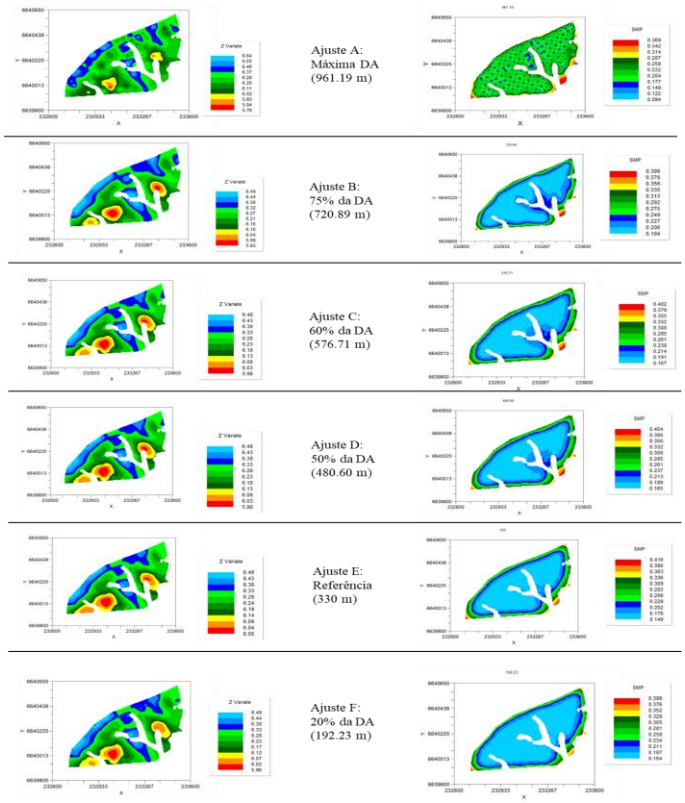
Contribuição	0,03042	0,02284	0,02006	0,01991	0,01978	0,0341
Alcance	415,20	246,50	191,30	185,00	129,90	99,00
SQR	1.38E-05	3.41E-05	1.47E-04	1.65E-04	1.98E-04	1.20E-03
R^2	93,50%	93,00%	70,60%	68,80%	64,40%	15,60%
IDE	61,90%	52,30%	50,10%	50,30%	50,10%	92,70%
DE	Moderada	Moderada	Moderada	Moderada	Moderada	Forte
			Validação Cruzada			
Coeficiente Angular	0,938	0,931	0,909	0,905	0,838	0,958
Erro Padrão	0,159	0,160	0,156	0,155	0,140	0,160
R^2	0,224	0,220	0,221	0,222	0,231	0,229
Intercepto	0,390	0,430	0,570	0,600	1,020	0,260
EPE	0,173	0,173	0,173	0,173	0,172	0,172

Legenda - DA: Distância de análise; SQR: Soma do quadrado dos resíduos; R^2: Coeficiente de determinação; IDE: Índice de dependência espacial; DE: Nível de dependência espacial; EPE Erro padrão de estimativa.

Ao analisar as validações cruzadas, em todos os ajustes realizados, o coeficiente angular apresentou valor próximo de um e o intercepto próximo de zero. Observou-se também valores estáveis para o erro padrão de estimativa (EPE), de 0,172 a 0,173. As linhas pontilhadas e contínuas, que representam os valores amostrados e estimados, mantiveram-se próximas, sendo que no ajuste a 75% DA, elas apresentaram o maior afastamento dentre os ajustes semivariográficos realizados. Por estas condições, as validações cruzadas seriam consideradas satisfatórias.

Ao avaliar visualmente as imagens interpoladas (Figura 3), foi observado que as regiões definidas pelas ocorrências de valores do índice SMP são similares para todos os ajustes semivariográficos realizados, exceto no ajuste com a máxima distância de análise, que produziu um padrão de regiões diferentes, com áreas menores e maior variabilidade e formação de "ilhas" ou pequenas manchas.

Figura 3. Estimativas e incertezas associadas (desvio padrão) obtidas por krigagem ordinária pontual para o Índice SMP, conforme os diferentes tamanhos de "cauda do patamar" em função da distância de análise utilizada nos ajustes semivariográficos - Fazenda Mata Grande, Vila Nova do Sul/RS, dados ano 2022.



Foi possível realizar a correlação dos mapas obtidos, a partir da conversão do pixel em pontos, contendo as estimativas do Índice SMP nos atributos. Todos os ajustes produziram estimativas não-normais segundo o teste de Kolmogorov-Smirnov (K-S Dist. variando de 0,047 a 0,078; p<0,001), sendo realizada a correlação de Spearman neste caso, aplicável para dados não-normais. As correlações de Spearman foram altas e significativas, o ajuste de referência (330,00 m) apresentou valores, em ordem decrescente, de 0,998; 0,997; 0,996; 0,984 e 0,931 todos com p<0,001 respectivamente para os ajustes 50% DA (480,60 m), 60% DA (576,71 m), 20% DA (192,23 m), 75% DA (720,89 m) e máxima distância de análise (961,19 m). Desta forma os mapas de valores do Índice SMP estimados por krigagem ordinária pontual, segundo cada forma de ajuste semivariográfico, foram similares. A estatística descritiva descritiva para os mapas obtidos por estes ajustes também demonstra isso (Tabela 3).

Mesmo os mapas obtidos serem similares, foi possível atender ao objetivo do trabalho, pois os mapas dos desvios padrões, ou seja, a incerteza associada às estimativas (Figura 3), bem como o coeficiente de variação (Tabela 3) e as menores correlações obtidas entre o ajuste de referência e os ajustes que produziram as maiores "caudas do patamar" mostraram que ao manter longas caudas no semivariogramas houve incremento de efeito aleatório nas estimativas, demonstrado pelo aumento do coeficiente de variação, desvio padrão e queda da correlação.

Tabela 3. Estatística descritiva para as estimativas de Índice SMP para ajustes semivariográficos conforme os diferentes tamanhos de "cauda do patamar" em função da distância de análise utilizada, Fazenda Mata Grande, Vila Nova do Sul-RS - Ano 2022.

	Ajuste do Semivariograma					
Distância de Análise (DA)	192,23m (20% DA)	330,00m (Referência)	480,60m (50% DA)	576,71m (60% DA)	720,89m (75% DA)	961,19m (Max DA)
M	6,26	6,26	6,26	6,26	6,26	6,26

EPm	0,00095	0,00092	0,00095	0,00095	0,00103	0,00114
Md	6,27	6,27	6,27	6,27	6,27	6,26
Mo	6,31	6,31	6,31	6,31	6,31	6,25
Vmx	6,49	6,48	6,48	6,48	6,49	6,64
Vmn	5,96	6,00	5,98	5,98	5,93	5,76
I	0,53	0,48	0,50	0,50	0,56	0,88
S^2	0,01139	0,01074	0,01137	0,01153	0,01353	0,01637
S	0,10670	0,10361	0,10665	0,10736	0,11632	0,12795
A	-0,38357	-0,37978	-0,40166	-0,40403	-0,42320	-0,32794
Ct	-0,45169	-0,53735	-0,48327	-0,46939	-0,29643	-0,09820
CV%	1,705	1,655	1,704	1,715	1,858	2,044
NC (95.0%)	0,0019	0,0018	0,0019	0,0019	0,0020	0,0022

Legenda - M: Média; EPm: Erro Padrão da média; Md: Mediana; Mo: Moda; Vmx: Valor máximo; Vmn: Valor mínimo; I: Intervalo; S^2: Variância dos dados; S: Desvio padrão; A: Assimetria; Ct: Curtose; CV%: Coeficiente de Variação (%); NC: Nível de confiança.

Segundo Corá et al. (2004), o valor do alcance determina o número de valores usados na interpolação, portanto, podem influenciar na qualidade das estimativas. De acordo com as estatísticas obtidas de raiz quadrada do erro médio (RMSE) e medida de viés (BIAS), aplicadas para comparar as estimativas obtidas com o ajuste de referência e relação às estimativas obtidas com os demais ajustes semivariográficos (Tabela 4), foram observados os menores valores de RMSE e BIAS entre o ajuste de referência e o 50% DA (480,60m). Já os maiores valores dessas estatísticas foram observados em relação aos ajustes que produziram as maiores "cauda do patamar", o que também indica estimativas com maiores diferenças.

Tabela 4. Tabela com a verificação do desempenho estatístico dos métodos paramétricos e não paramétricos empregados na estimativa do Índice SMP, conforme cada distância.

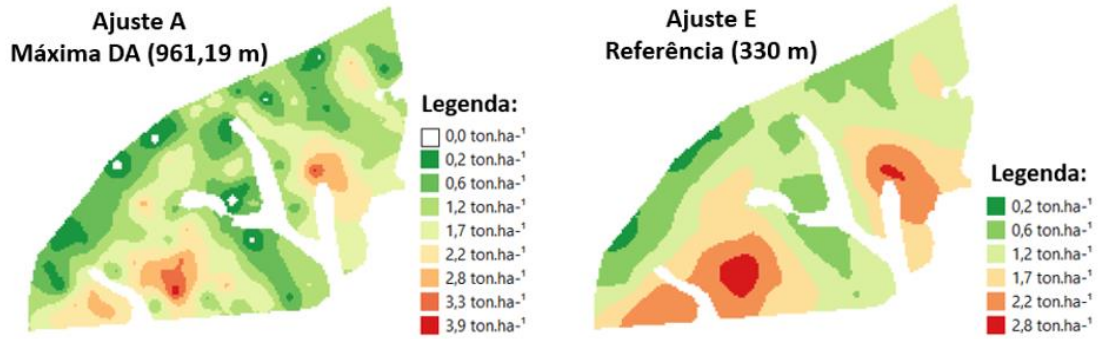
		Verificação de Desempenho Estatístico				
Distância de Análise (DA)	330,00m (Referência)	192,23m (20% DA)	480,60m (50% DA)	576,71m (60% DA)	720,89m (75% DA)	961,19m (Max DA)
RMSE	-	0,01748	0,00861	0,01482	0,0262	0,09011
RMSE (%)	-	28%	14%	24%	42%	144%
BIAS	-	0,00015	-0,00007	-0,00013	-0,00023	0,00080
BIAS (%)	-	0,24%	-0,12%	-0,21%	-0,37%	1,28%

Legenda - RMSE: Raiz do erro do quadrático médio; RMSE (%): Raiz do erro do quadrático médio relativo em percentagem; BIAS: Desvio sistemático do valor real apresentado por um valor estimado

via modelagem para esse valor de referência; BIAS (%): Desvio sistemático do valor real apresentado por um valor estimado via modelagem para esse valor de referência relativo em percentagem.

Quando comparadas as necessidades de calagem, em função dos diferentes ajustes semivariográficos realizados, observou que para a área total, todos os ajustes realizados demandaram a aplicação de 43 toneladas de calcário. No entanto, observou-se diferença espacial para as áreas de aplicação (Figura 4). O ajuste semivariográfico de referência produziu áreas maiores e recomendou menores doses de calagem. Já o ajuste realizado com a máxima DA, produziu áreas menores, identificando áreas com maiores necessidade de calagem e também áreas sem necessidade de aplicação. Porém, na prática, o mapa da necessidade de calagem obtido com o ajuste de referência seria o preferível.

Figura 4. Necessidade de calagem segundo o Índice SMP para ajustes semivariográficos, conforme os diferentes tamanhos de "cauda do patamar" em função da distância de análise utilizada, Fazenda Mata Grande, Vila Nova do Sul-RS - Ano 2022.



CONCLUSÃO

Todas as análises realizadas mostraram que ao utilizar semivariogramas com "caudas longas" houve incremento de efeito aleatório nas estimativas. Todos os ajustes proporcionaram a mesma necessidade de calagem para área total (43 t.ha-¹), segundo o índice SMP, porém com diferença na distribuição das doses e nos tamanhos de áreas de aplicação. Recomenda-se aos usuários de geoestatística e krigagem ordinária pontual atenção aos procedimentos de ajuste dos semivariogramas, pois a qualidade do ajuste afetará diretamente as estimativas realizadas por krigagem ordinária pontual nos mapas obtidos. É necessário avaliar os efeitos (agronômico, econômico, operacional e ambiental) na prescrição de manejo/intervenção de cada atributo do sistema produtivo, representado por mapas que contenham em suas estimativas esse incremento de efeito aleatório, aumento da incerteza associadas às estimativas, devido a presença de "cauda do patamar", no processo de tomada de decisão na gestão de lavouras.

AGRADECIMENTOS

Agradecemos ao Programa de Pós-Graduação em Agricultura de Precisão do Colégio Politécnico da Universidade Federal de Santa Maria (UFSM) pelo suporte institucional para o desenvolvimento desta pesquisa, bem como à empresa Base Precisão na Agricultura pela disponibilização dos dados essenciais para este estudo.

REFERÊNCIAS

CORÁ, J. E. et al. **Variabilidade espacial de atributos do solo para adoção do sistema de agricultura de precisão na cana-de-açúcar**. Revista Brasileira de Ciência do Solo, Viçosa, Vol. 28, n. 6, p. 1013-1021, 2004.

GREGO, C. R.; OLIVEIRA, R. P. de; VIEIRA, S. R. **Geoestatística aplicada a Agricultura de Precisão.** Embrapa Territorial, 2014.

ROBERTSON, G. P. **GS+: geostatistics for the environmental sciences.** Plainwell: Gamma Design Software, 1998. 152 p.

SANTOS, R.S. **GS+. Smart-Map. Geostatistical analysis and map correlation using the software:** GS+ and the Smart-Map plugin of QGIS GIS. 2023. 9 p.

SHOEMAKER, H.E.; McLEAN, E.O. & PRATT, P.F. B**uffer methods for determining the lime requirement of soils with appreciable amounts of extractable aluminum.** Soil Sci. Soc. Am. Proc., 25:274-277, 1961.

STRECK, Edemar Valdir et al.; FLORES, Carlos Alberto; SCHNEIDER, Paulo (Clbs.) **Solos**

do Rio Grande do Sul. 3. ed., rev. e ampl. Porto Alegre: Emater/RS-Ascar, 2018. 252 p.

TOLEDO, J.A. **Solução Tampão que mimetiza as características ácido-base do tampão em resposta à acidez de solos brasileiros.** Dissertação (Mestrado em Ciência do Solo) - Programa de Pós-Graduação em Agronomia, Universidade Federal de Santa Maria, Santa Maria-RS, 2011.

WREGE, M. S. et al. **Atlas climático da região Sul do Brasil:** estados do Paraná, Santa Catarina e Rio Grande do Sul. Brasília, DF: Embrapa, 2012. 334 p.

YAMAMOTO, Jorge Kazuo; LANDIM, Paulo M. Barbosa. **Geoestatística:** Conceitos e aplicações. São Paulo: Oficina de Textos, 2013. 215 p.

ZIMBACK, C. R. L. An**álise espacial de atributos químicos de solos para fins de mapeamento da fertilidade do solo.** 2001. 114f. Tese (Livre-Docência em Levantamento do solo e Fotopedologia) - Universidade Estadual Paulista, Botucatu, 2001.

VARIABILIDADE ESPACIAL DA DISPERSÃO RELATIVA DE VALORES INTERPOLADOS DO NDVI MEDIDO EM VIDEIRAS E MONITORADO EM CONDIÇÃO DE SATURAÇÃO

Bruno Ricardo Silva Costa [1]; Henrique Oldoni [2]; Luis Henrique Bassoi [3]

[1]Bolsista de pós-doutorado. R. 15 de Novembro, 1452 - Centro, São Carlos - SP, 13560-970. Embrapa Instrumentação; [2]Bolsista de pós-doutorado. Av. André Tosello, 209, Campus da Unicamp - Barão Geraldo, Campinas - SP, 13083-886 . Embrapa Agricultura Digital; [3]Pesquisador. R. 15 de Novembro, 1452 - Centro, São Carlos - SP, 13560-970. Embrapa Instrumentação

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Mapas do Índice de Vegetação por Diferença Normalizada (NDVI) podem exibir uma aparente uniformidade devido a pequena amplitude dos valores obtidos quando este índice é mensurado em coberturas vegetais adensadas, em razão da sua saturação. Contudo, a análise da dispersão relativa destes resultados pode indicar diferenças na variação média do NDVI em determinadas regiões dos mapas. Neste sentido, este trabalho propõe avaliar se a caracterização da variabilidade espacial do coeficiente de variação (CV) de valores interpolados do NDVI pode revelar locais discrepantes em condições presumidamente homogêneas. Dados georreferenciados da reflectância do dossel de videiras cv. Cabernet Franc (*Vitis vinifera* L.) foram coletados em dois ciclos de produção em um vinhedo comercial, via sensoriamento proximal, para o cálculo do NDVI no período do pintor (*veraison*). Mapas interpolados foram renderizados via análise geoestatística e krigagem a partir destes dados. O CV foi calculado de forma localizada para cada pixel componente dos mapas, a partir da média e do desvio padrão dos valores do NDVI restritos em uma janela predeterminada de n = 20 pixels no seu entorno. Após o cálculo do CV, os resultados foram classificados em duas zonas homogêneas e comparou-se as distribuições dos dados do NDVI correspondentes a cada zona em termos de medidas de tendência central, dispersão e forma (curtose e assimetria). Foram observadas diferenças localizadas no CV nos mapas de NDVI, que revelaram regiões com uniformidade variável, a despeito da pequena amplitude de variação do índice estimado globalmente. Após o zoneamento do CV, houve alteração nas estatísticas utilizadas para descrever a distribuição dos dados do NDVI componentes do mapa original em comparação àqueles contidos em cada zona.

PALAVRAS-CHAVE: vitivinicultura; índice de vegetação; coeficiente de variação

ABSTRACT

Maps of the Normalized Difference Vegetation Index (NDVI) may exhibit apparent uniformity due to the small range of the values obtained when this index is measured in dense vegetation cover, due to its saturation. However, the analysis of the relative dispersion of these results may indicate differences in the average variation of the NDVI in certain regions of the maps. In this sense, this work proposes to evaluate whether the characterization of the spatial variability of the coefficient of variation (CV) of interpolated NDVI values can reveal discrepant locations in a presumably homogeneous scenario. Georeferenced data of the canopy reflectance of cv. Cabernet Franc grapevines (*Vitis vinifera* L.) were collected in two growth cycles in a commercial vineyard, via proximal sensing, to calculate the NDVI in *veraison*. Interpolated maps were rendered using geostatistical analysis and kriging from these data. The CV was calculated locally for each component pixel of the maps, based on the mean and standard deviation of the NDVI values restricted to a predetermined window of n = 20 pixels around them. After calculating the CV, the results were classified into two homogeneous zones. The distributions of the NDVI data corresponding to each zone were compared in terms of central tendency, dispersion, and shape (kurtosis and skewness).

Localized differences in the CV were observed in the NDVI across the maps, revealing regions of varying uniformity, despite the overall small variation in the globally estimated index. After zoning the CV, there was a change in the statistics used to describe the distribution of the NDVI data in the original map compared to those in each zone.

KEYWORDS: viticulture; vegetation index; coefficient of variation

INTRODUÇÃO

O NDVI continua sendo utilizado atualmente para o monitoramento de áreas agrícolas com a finalidade de detecção da variabilidade espacial do desenvolvimento vegetativo das plantas, especialmente em resposta a condições ambientais (DING et al., 2022; LI et al., 2023), apesar da possibilidade de saturação deste índice no monitoramento de dosséis adensados (HUANG et al., 2021; MUTANGA et al., 2023). Neste sentido, a saturação do NDVI ocorre quando o índice se torna menos sensível para detecção de variações na vegetação, em razão da discrepância entre a reflectância (ρ) correspondente a região do infravermelho próximo e do vermelho em resposta a um maior índice de área foliar. Desta forma, os valores do NDVI se aproximam do seu limite máximo (i.e., 1,0), até um momento em que a sua variação é mínima, quando qualquer incremento na biomassa ou no teor de pigmentos fotossintéticos (clorofila) não mais produz efeito significativo sobre o índice. Esta condição pode ser observada comumente em vinhedos cultivados com variedades vigorosas, sem restrição hídrica, sob práticas homogêneas de manejo e em fases avançadas do ciclo de produção. Contudo, apesar da uniformidade subtendida nesta situação, o monitoramento e mapeamento do desenvolvimento vegetativo das videiras é fundamental para a adoção de práticas de agricultura de precisão (AP) na viticultura, pois possibilita a delimitação de zonas homogêneas do vigor vegetativo, que podem diferir entre si em termos de produção e qualidade de uvas (OLDONI, et al., 2021). Neste sentido, apesar das tecnologias de sensoriamento remoto estarem prontamente disponíveis para o monitoramento de vinhedos, esta avaliação pode ser otimizada por meio da utilização de sensores proximais. Estes oferecem vantagens específicas para aplicação em viticultura em comparação ao sensoriamento remoto, especialmente relacionadas ao reduzido tamanho dos vinhedos, que restringe o uso de imagens de satélite. Assim, esses equipamentos possibilitam uma maior resolução espacial e temporal do monitoramento, permitindo uma análise mais detalhada das condições do dossel. Entretanto, faz-se necessário reavaliar os resultados produzidos pelos sensores proximais que adotam o NDVI como padrão para monitoramento do vigor vegetativo em vinhedos, particularmente quando ocorre a saturação deste índice. Nestas condições, apesar do NDVI sugerir uma uniformidade genérica em toda a área, uma pequena amplitude de valores elevados deste índice pode ocultar uma variabilidade subjacente significativa, localizada em determinadas regiões, o que ressalta a necessidade de alternativas para detectar e caracterizar a magnitude dessas variações. Neste contexto, a análise da variabilidade espacial de medidas de dispersão dos valores do NDVI, a exemplo do coeficiente de variação (CV), que relaciona o desvio padrão à média dos dados, pode ser sugerida de forma complementar ao monitoramento do índice em si.

OBJETIVOS

Este estudo propõe avaliar se a caracterização espacial do CV referente ao NDVI pode revelar variações localizadas em mapas interpolados, renderizados a partir de dados obtidos via sensoriamento proximal e coletados em um vinhedo comercial durante o ápice de crescimento das videiras.

MATERIAL E MÉTODOS

Medidas georreferenciadas da ρ do dossel de videiras cv. Cabernet Franc (*Vitis vinifera* L.) foram tomadas ao longo de todas as fileiras de plantas de um vinhedo comercial, submetido a dupla poda

anual (FAVERO et al., 2011), em uma única ocasião durante o estádio fenológico do pintor (i.e., *veraison*), em dois ciclos de produção consecutivos, em 2018 e 2019. As medidas mencionadas foram tomadas utilizando-se o sensor ativo ACS-430 CropCircle (*Holland Scientific*, Lincoln, NE, EUA), posicionado acima do dossel das plantas, e utilizadas para o cálculo do NDVI (Equação 1)

$$NDVI = (\rho_{NIR} - \rho_R)/(\rho_{NIR} - \rho_R) \quad (1)$$

Onde: ρ_{NIR} e ρ_R equivalem à ρ nos comprimentos de onda de 780 (infravermelho próximo) e 670 nm (vermelho), respectivamente.

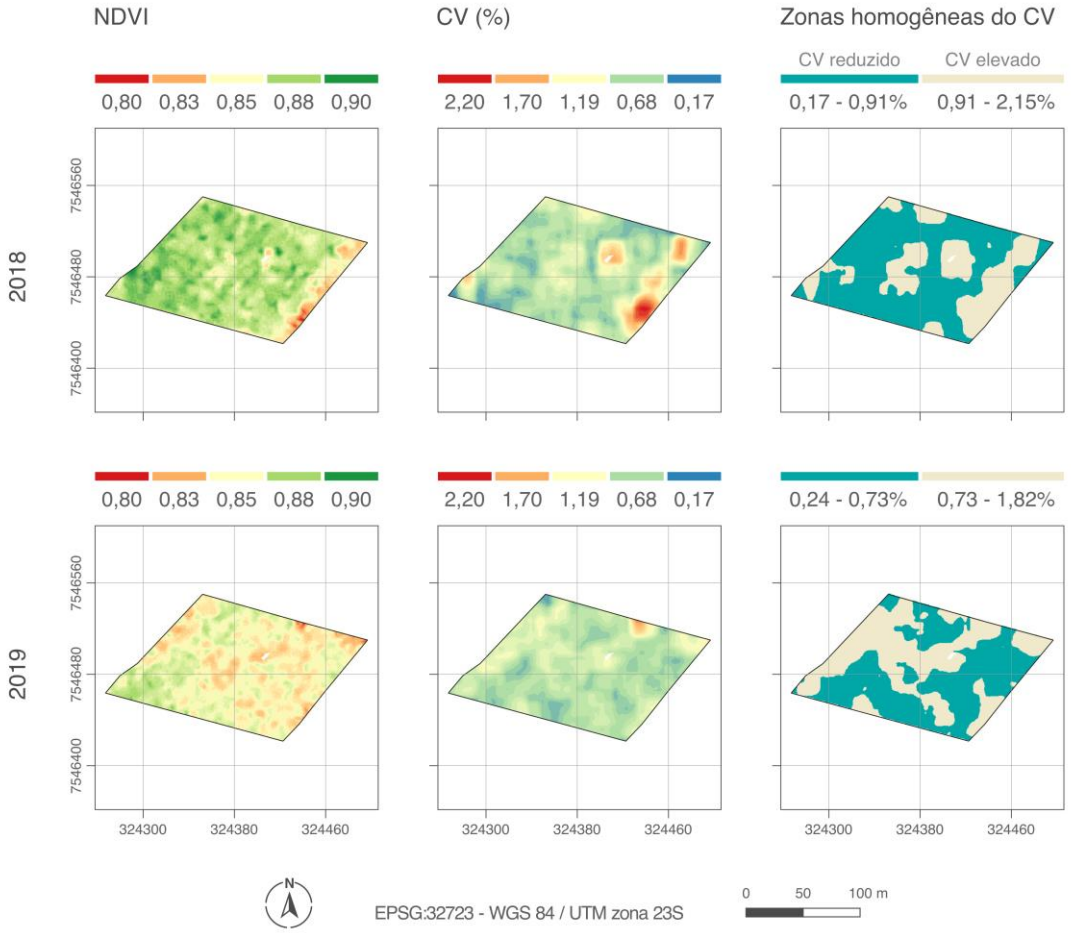
A renderização de mapas interpolados do NDVI foi feita a partir da análise geoestatística e predição espacial, utilizando-se o software Vesper 1.6 - *Variogram Estimation and Spatial Prediction plus Error* (MINANSY et al., 2005). Na análise geoestatística, semivariogramas teóricos foram ajustados aos experimentais de forma automática, a partir da predefinição do modelo teórico exponencial, adotando-se o modo local disponibilizado no software mencionado, em razão da densidade amostral dos dados de campo (n > 5000 pontos). Na sequência, a predição espacial foi realizada pelo método de krigagem ordinária, adotado para estimativa de valores do NDVI em posições não abrangidas pela amostragem, em uma grade regular definida pelo contorno do vinhedo, considerando-se uma resolução espacial de 0,50 m. Por fim, os resultados interpolados do NDVI foram exportados em imagens no formato de arquivos matricial (i.e., *raster*).

A partir dos valores interpolados do NDVI, calculamos o CV conforme a razão entre a média e o desvio padrão dos valores dispostos em uma janela de n= 20 pixels localizados no entorno de cada pixel dos mapas. O cálculo do CV levou em conta uma correção do efeito de borda, que garantiu que os pixels próximos às bordas dos arquivos raster fossem contabilizados, resultando em mapas de mesma dimensão em comparação àqueles do NDVI. Após o cálculo do CV em cada data de monitoramento, estes valores foram classificados adotando-se o algoritmo CLARA (*Clustering Large Applications*) para a delimitação duas de zonas homogêneas. Em seguida, calculamos medidas de tendência central, dispersão e formato da distribuição dos dados interpolados do NDVI coincidentes com cada zona homogênea do CV para fins de comparação.

RESULTADOS E DISCUSSÃO

A Figura 1 apresenta os mapas interpolados do NDVI em cada data de avaliação e a correspondente distribuição espacial do CV, seguida da delimitação de zonas homogêneas desta estatística. A despeito da disposição do NDVI no vinhedo, o mapeamento do CV permitiu a observação de discrepâncias na variabilidade interna dos mapas em ambos os anos. Assim, apesar do monitoramento ter sido realizado em uma mesma fase do ciclo, os mapas do CV apresentaram locais de maior ou menor uniformidade em regiões distintas quando comparados entre si. Por exemplo, em 2018, uma maior variação local do NDVI se deu no sentido leste, leste-sudeste e sudeste do vinhedo, enquanto no ano seguinte, esta variação foi menor neste mesmo local, destacando a dinâmica espacial das condições de cultivo. Por sua vez, a delimitação das zonas homogêneas do CV em cada data revelou regiões com maior ou menor dispersão quanto ao NDVI e que coincidiram ou não entre os anos, apesar da aparente uniformidade no desenvolvimento vegetativo das videiras, devido a pequena amplitude de variação do NDVI obtida em cada monitoramento.

FIGURA 1. Variabilidade espacial do NDVI e do seu desvio relativo médio, i.e., coeficiente de variação (CV), e zonas homogêneas do CV delimitadas em vinhedo durante o estádio de pintor (*veraison*) em dois ciclos de produção consecutivos.

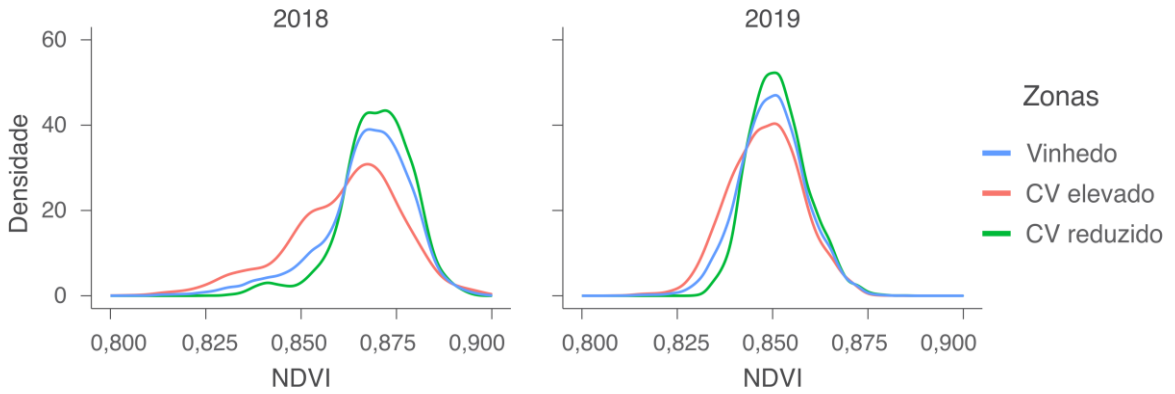


A Tabela 1 apresenta a estatística descritiva quanto aos dados do NDVI no vinhedo como um todo e àqueles correspondentes a cada zona homogênea do CV, indicando as diferenças na distribuição dos dados após a análise da dispersão deste índice de vegetação em comparação aos dados dos rasters originais. A Figura 2 caracteriza a distribuição dos dados do NDVI no vinhedo e em cada zona do CV em gráficos de densidade.

TABELA 1. Estatística descritiva dos valores interpolados do NDVI em cada data de monitoramento, correspondentes aos arquivos rasters originais e as zonas homogêneas do CV

Zona	Média	Desvio	Mínimo	Máximo	CV	assimetria	curtose
			2018				
Vinhedo	0,867	0,012	0,8001	0,8998	1,4227	-1,0161	1,7130
CV elevado	0,861	0,015	0,8001	0,8998	1,7340	-0,6071	0,4076
CV reduzido	0,870	0,010	0,8247	0,8962	1,1030	-0,7657	1,3715
			2019				
Vinhedo	0,850	0,009	0,8079	0,8852	1,0229	-0,0325	0,3035
CV elevado	0,848	0,010	0,8079	0,8830	1,1246	-0,0659	0,0173
CV reduzido	0,851	0,008	0,8298	0,8852	0,8906	0,3719	0,0505

FIGURA 2. Gráficos de densidade da distribuição dos dados NDVI correspondentes aos arquivos rasters originais e às zonas homogêneas do CV



As discrepâncias nas medidas de tendência central e dispersão quanto a distribuição dos dados do NDVI em todo o vinhedo e após a delimitação das zonas homogêneas do CV foi mais aparente no mapa produzido durante o ciclo de produção de 2018, em razão da maior dispersão relativa dos dados nesta ocasião (CV = 1,4%). O valor médio do NDVI monitorado neste primeiro ciclo evidenciou um maior vigor vegetativo das videiras em comparação ao seguinte, indicando variações sazonais do desenvolvimento vegetativo no vinhedo. Além disso, a variabilidade em cada zona homogênea do CV também decresceu em 2019, sugerindo uma maior uniformidade na distribuição espacial do vigor vegetativo nesta ocasião, conforme observado nos mapas.

Em ambos os ciclos de produção, após a delimitação das zonas de CV, a zona de maior dispersão (CV elevado) apresentou, presumidamente, um maior CV e NDVI médio ligeiramente menor em comparação ao conjunto de dados geral. Por sua vez, a zona de menor dispersão (CV reduzido) apresentou um menor CV e um NDVI médio mais alto em comparação aos dados do vinhedo como um todo, indicando videiras mais vigorosas e semelhantes entre si quanto ao desenvolvimento vegetativo. As diferenças no formato da distribuição dos dados também foram mais pronunciadas no ciclo de produção de 2018. Neste monitoramento, os dados do NDVI dos rasters originais apresentaram uma distribuição com assimetria negativa (à esquerda) e curtose positiva, classificada como leptocúrtica, i.e., com a maioria dos dados concentrados em torno da média e menor quantidade de valores discrepantes. Entretanto, após a classificação do CV, apesar da distribuição dos dados do NDVI localizados na zona de maior dispersão apresentar uma assimetria ainda à esquerda, esta foi menos negativa em comparação com àquela referente ao conjunto de dados geral do NDVI. A curtose foi menor e classificada como platicúrtica, sugerindo uma distribuição mais plana, comprovando a maior variabilidade no vigor das videiras localizadas nesta zona. Em contrapartida, apesar da zona de menor dispersão também apresentar uma distribuição de dados do NDVI com uma assimetria menos negativa que àquela correspondente ao o conjunto de dados geral, esta foi mais negativa do que na zona de maior dispersão. A curtose também foi relativamente alta, e classificada como leptocúrtica, de forma semelhante ao conjunto de dados geral, indicando novamente um pico acentuado na distribuição de NDVI, que reflete a menor variabilidade em razão da concentração de valores em torno da média. Os resultados referentes aos dados de NDVI do ciclo de produção de 2019 demonstram distribuições mais semelhantes entre si quanto a assimetria, que foi próxima de zero em todos os casos, em comparação com os resultados do ciclo anterior, mesmo após a delimitação das zonas homogêneas do CV. Contudo, foi observada uma redução na curtose, ao se comparar a distribuição do NDVI nas zonas de maior e menor dispersão, a semelhança do resultado observado no ciclo de 2018, corroborando novamente a validade do mapeamento da dispersão do NDVI monitorado nestas condições para identificação de diferenças localizadas quanto a variabilidade do desenvolvimento vegetativo das videiras.

Os resultados deste estudo destacam que apenas a amplitude do NDVI pode não ser o suficiente para captar a variabilidade espacial, especialmente em áreas com condições supostamente homogêneas e quando o índice atinge a saturação. Neste contexto, sugerimos o mapeamento de medidas de dispersão estatística deste índice para indicar regiões com diferentes níveis de homogeneidade quanto ao vigor vegetativo em uma mesma área cultivada. A validação desse zoneamento pode ser realizada posteriormente em termos de produção e qualidade de frutos e, em caso de diferenças significativa entre as zonas, pode ser utilizada para adoção de práticas de AP, a exemplo da colheita seletiva (OLDONI, et al., 2021).

CONCLUSÃO

A análise da variabilidade espacial da dispersão relativa do NDVI em mapas interpolados permite a identificação, de forma localizada, de diferentes níveis de variação deste índice, mesmo em condições de saturação que sugerem uma uniformidade generalizada do desenvolvimento vegetativo das plantas em uma área cultivada (i.e., videiras em um vinhedo).

AGRADECIMENTOS

À Vinícola Guaspari (Espírito Santo do Pinhal - SP) pela concessão do vinhedo para monitoramento. À Embrapa Instrumentação pela disponibilidade de infraestrutura para realização da pesquisa. Ao CNPq pela concessão de bolsa ao primeiro ao autor no período de realização deste estudo.

REFERÊNCIAS

DING, Y.; HE, X.; ZHOU, Z.; HU, J.; CAI, H.; WANG, X.; LI, L.; XU, J.; SHI, H. Response of vegetation to drought and yield monitoring based on NDVI and SIF, **Catena** v.219, 2022.

FAVERO, A.C., AMORIM, D.A., MOTA, R.V., SOARES, A.M., SOUZA, C.R., & REGINA, M.A. Double-pruning of 'Syrah' grapevines: a management strategy to harvest wine grapes during the winter in the Brazilian Southeast. **Vitis**, v.50, n.4, p.151-158, 2011.

HUANG, S.; TANG, L.; HUPY, J.P.; WANG, Y.; SHAO, G. A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing, **Journal of Forestry Research**, v.32, 2021.

LI, X.; WANG X.; WU J.; LUO W.; TIAN L.; WANG, Y.; LIU, Y.; ZHANG, L.; ZHAO, C.; ZHANG, W. Soil Moisture Monitoring and Evaluation in Agricultural Fields Based on NDVI Long Time Series and CEEMDAN. **Remote Sensing**, v.15, n.20, 2023.

MINASNY, B., MCBRATNEY, A. B., WHELAN, B. M. Vesper version 1.62. Sydney, Australian Centre for Precision Agriculture, The University of Sydney, 2005.

MUTANGA, O.; MASENYAMA, A.; SIBANDA, M. Spectral saturation in the remote sensing of high-density vegetation traits: A systematic review of progress, challenges, and prospects, **ISPRS Journal of Photogrammetry and Remote Sensing**, v.198, p.297-309, 2023.

OLDONI, H.; COSTA, B.R.S.; BOGNOLA, I. A.; SOUZA, C.R.; BASSOI, L.H. Homogeneous zones of vegetation index for characterizing variability and site-specific management in vineyards. **Scientia Agricola**, v. 78, 2021.

RELAÇÃO ENTRE MAPA DE ZONAS DE POTENCIAL PRODUTIVO COM VARIÁVEIS DE SOLO DE INTERESSE AGRONÔMICO

LARA MARIE GUANAIS SANTOS [1]; MARIA DE FATIMA GUIMARÃES [2]; HEVANDRO COLONHESE DELALIBERA [3]

[1]Bolsista. Rodovia Celso Garcia Cid, PR 445 Km 380, Campus Universitário Cx. Postal 10.011, CEP 86.057-970, Londrina - PR. Universidade Estadual de Londrina ; [2]Docente. Rodovia Celso Garcia Cid, PR 445 Km 380, Campus Universitário Cx. Postal 10.011, CEP 86.057-970, Londrina - PR. Universidade Estadual de Londrina ; [3]Pesquisador cinetífico. Rodovia Celso Garcia Cid, km 375 - 86047-902 - Londrina - PR . Instituto de Desenvolvimento Rural do Paraná IAPAR-Emater

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

Os mapas de produtividade além de representar a resposta da cultura ao manejo, são considerados dados de baixo custo de obtenção. Neste trabalho foi avaliado o desempenho da metodologia de geração de mapa de zonas de potencial produtivo a partir de dados de produtividade coletados por monitores de colheita, em se relacionar com as variáveis de solo local. Foi confeccionado um mapa de zonas de potencial produtivo de uma área agrícola localizada em Cândido Mota-SP. Este mapa, foi feito a partir do histórico de mapas de produtividade de três safras de soja e três de milho. As zonas de potencial produtivo foram utilizadas como referência para o direcionamento de amostragem para diversos tipos de analises de solo. Com estes, os modelos multivariados aplicados apresentaram relação de 84,5% entre o mapa de zonas de potencial produtivo, com as variáveis de solo, sendo os macroporos e a porosidade total as variáveis mais importantes. Por fim, também pode-se afirmar que a metodologia de separação em três zonas de potencial produtivo é útil para determinação dos locais a serem amostrados na área agrícola, reduzindo o número de pontos amostrais, direcionando a amostragem por meio de informação quantitativa, evitando amostragens em grade, de forma aleatória e empírica e em grande quantidade.

PALAVRAS-CHAVE: Colheita de grãos; Análise de dados; Método Jackknife

ABSTRACT

Productivity maps, besides representing the crop's response to management, are considered low-cost data to obtain. This study evaluated the methodology's performance for generating productive potential zone maps from productivity data collected by harvest monitors, concerning local soil variables. A potential production zone map was created for an agricultural area in Cândido Mota-SP. This map was created based on the historical productivity maps of three soybean and three corn harvests. The productive potential zone was used as a reference for directing sampling for different types of soil analysis. With these, the applied multivariate models presented a relationship of 84.5% between the productive potential zone map and the soil variables, with macropores and total porosity being the most essential variables. Finally, it can also be stated that the methodology of separation into three productive potential zone is helpful for determining the locations to be sampled in the agricultural area, reducing the number of sampling points, directing sampling through quantitative information, avoiding grid sampling, random and empirical sampling and in large quantities.

KEYWORDS: Grain harvest; Data analysis; Método Jackknife

INTRODUÇÃO

Melhorar a produtividade e a qualidade do rendimento das culturas com o aumento da eficiência no uso dos recursos e concomitantemente podendo se reduzir os custos, é o objetivo fundamental na agricultura de precisão (AP) (ROBERTS & MATTOO, 2019). O potencial de crescimento e rendimento de uma cultura depende de muitos atributos de produção diferentes, como clima, propriedades do solo, topografia, irrigação e manejo de fertilizantes (CHLINGARYAN, 2018). Para identificar essas regiões dos talhões com potenciais produtivos distintos são utilizadas algumas ferramentas de AP, como Sistema Global de Navegação por Satélite (GNSS) e os Sistemas de Informação Geográficas (SIG), o uso dos mapas de produtividade para avaliar a variabilidade do local do solo e da planta, fornecem dados relevantes para ajudar os produtores no gerenciamento mais preciso e assertivo do sistema agrícola (PATHAK et al., 2019). Um dos benefícios gerados é a redução de custos da produção agrícola, proporcionando um aumento da competitividade e benefícios ambientais (OLIVEIRA e SARAIVA, 2015). Também os mapas de produtividade se mostram muito promissores para identificação de variabilidade pois integram os efeitos de diversas variáveis espaciais, como propriedades do solo, taxas de fertilizantes, atributos topográficos, condições climáticas e ocorrência de infestações por insetos e doenças (SOUZA et al., 2016). Segundo estudo realizado por Wachowiak et al. (2017), são grandes os ganhos com a utilização desta tecnologia. Entretanto, estes mapas de rendimento, em si, não são ferramentas de conhecimento ou decisão, para tanto, é necessário incorporá-los aos processos de tomada de decisão, análise e planejamento geral das operações da propriedade. Para obtenção de um bom mapa é necessário decidir como os dados serão tratados. Alguns métodos não preservam necessariamente a variabilidade do conjunto de dados original, em função de uma estimativa dos intervalos entre os pontos amostrais e podem produzir resultados diferentes para o mesmo conjunto de dados (SOUZA et al., 2016). O método proposto por Santos et al. (2023), utilizado para o tratamento de dados advindos de monitor de colheita, se mostra uma metodologia promissora para atribuir confiabilidade aos dados de produtividade, possibilitando transformar dados em informação, através da definição de zonas de manejo, empregando procedimentos estatísticos como a conversão da produtividade em escore-? para a comparação com a estatística z, permitindo a exclusão de dados fora do intervalo estabelecido através dos métodos do grau de linearidade e aplicação do método Jackknife. O mapa de zonas de potencial produtivo resultante, contêm informações essenciais de diagnose da variabilidade da área agrícola e, consequentemente, permitindo a realização de intervenções. Assim, na hipótese de que o mapa de zonas de potencial produtivo tem correlação com as variáveis de solo e é adequado para a realização de amostragem e de inferência e recomendação de manejo da área, o objetivo deste trabalho foi verificar a existência de relação entre a metodologia proposta por Santos et al. (2023) com variáveis de solo.

OBJETIVOS

O objetivo deste trabalho foi verificar a existência de relação entre mapa de zonas de potencial produtivo gerado a partir de dados advindos de monitor de colheita, com variáveis de solo.

MATERIAL E MÉTODOS

Os dados utilizados foram provenientes de três safras da cultura do milho (safras 2017, 2019 e 2020) e três da soja (safras 2015, 2016 e 2019), de uma área agrícola de 23 ha, conforme a Figura 3, sob Plantio Direto, em Latossolo Vermelho (Santos et al., 2018), com 52% de argila, localizada no município de Candido Mota - SP, (22°53'57.10"S; 50°23'58.11"O), 368 m de altitude, clima Cfa (KÖPPEN, 1931).

Os dados foram obtidos por meio de uma colhedora de grãos modelo STS 9750/John Deere, equipada com monitor de produtividade modelo GS4, John Deere®, que apresenta, grava e disponibiliza os dados em formato de planilha eletrônica. Primeiramente os dados nulos e zerados foram excluídos. A produtividade medida pelo sensor de massa foi corrigida para 13% de umidade pelo método

proposto por Aguiar (1977). Após a correção da umidade, os dados foram tratados pela avaliação do grau de linearidade da frequência ordenada dos escore-?, se excluindo valores extremos até atingir $r^2 \geq 0,80$. Posteriormente também foi aplicado o método Jackknife com exclusão dos dados fora do intervalo de -3,09 a 3,09, permitindo o ajuste a distribuição z, conforme descrito Santos et al. (2023), se obtendo um mapa de escore-? para cada uma das culturas, mapas pelo qual que representam a variabilidade intrínseca do conjunto de dados para cada safra. Posteriormente foi realizada a álgebra dos mapas no software QGis 3.22.8, resultando em um mapa médio que é denominado mapa de potencial produtivo da área. Este procedimento permite a diluição dos efeitos de fatores não controlados como clima e planta obtendo-se uma informação resumida das variações intrínsecas das produtividades da área, resumindo a quantidade de fatores, facilitando a interpretação dos resultados através das inferências em sua distribuição de forma conjunta. Seguindo a metodologia, para definição das zonas de potencial produtivo, o mapa foi classificado através do método do intervalo de confiança, onde, locais com índices menores que -1 de escore-? foram considerados zonas de baixo índice de potencial produtivo, entre -0,999 a 0,999, foram consideradas de potencial médio normal e, acima de 1 escore-?, foram consideradas zonas de alto índice de potencial produtivo, conforme a Figura 1. Com base neste mapa de zonas de potencial produtivo, foram definidos os locais e a quantidade de amostras a serem coletadas para o discorrer do trabalho. Foram realizadas a coleta de vinte e uma (21) amostras compostas de solos a campo, conforme disposto na Figura 1, compondo sete (7) amostras para cada zona de potencial produtivo. As coletas de amostra de solo foram retiradas em três profundidades de coleta 0 a 5cm, 5 a 10cm e 10 a 20cm. Os pontos enumerados de 1 a 7 foram posicionados na área de alto potencial produtivo, de 8 a 14 foram alocados na área de médio potencial produtivo e de 15 a 21 na área de baixo potencial produtivo. Nos vinte e um (21) pontos amostrais, em ambas as profundidades, foram avaliados para os atributos químicos carbono orgânico (CO), matéria orgânica (MO), pH CaCl, pH água, pH SMP, H+Al, Al, cálcio (Ca), magnésio (Mg), fosforo (P) e potássio (K). Para os atributos físicos foram avaliados a granulometria, argila dispersa em água (ADA), diagnóstico rápido da estrutura do solo (DRES), estabilidade de agregados densidade do solo, tensão de retenção de água, macro porosidade e micro porosidade. Foram levantadas quarenta e uma (41) variáveis no total, submetidas a análise estatística multivariada realizada no programa computacional Pirouette 4.5, Infometrix Inc.®. Foram realizadas duas análises baseadas em escalonamento multidimensional, sendo uma análise exploratória, seguida pela aplicação de um método classificatório. Como método exploratório utilizou-se a análise Principal Component Analysis (PCA) e como método classificatório Soft Independent Modeling of Class Analogy (SIMCA). O intuito destas análises foi verificar a existência de relação entre as zonas de potencial produtivo, com as variáveis de solo coletadas de acordo com o zoneamento.

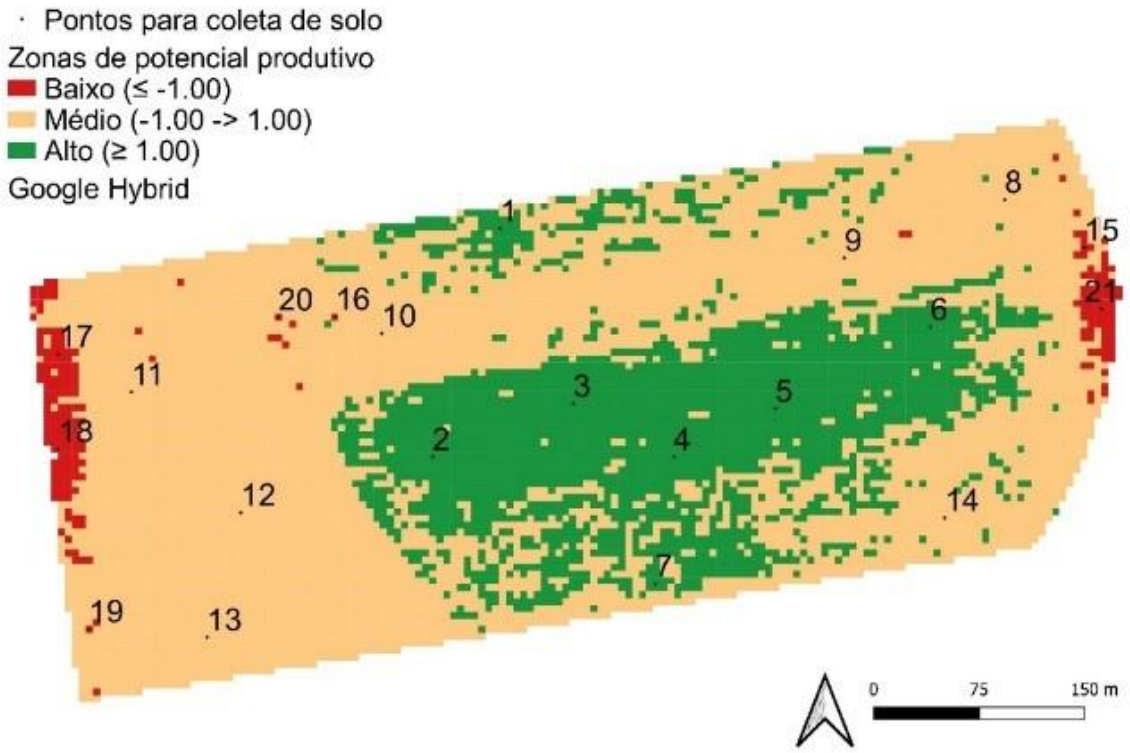


FIGURA 1. Mapa de zonas de potencial produtivo e sua subdivisão em três classes com a distribuição dos vinte e um (21) pontos amostrais.

RESULTADOS E DISCUSSÃO

A PCA foi aplicada com o intuito de avaliar a formação de agrupamentos de acordo com a classe aplicada, sendo as classes dos quais o conjunto de amostras foram submetidas, as mesmas da classificação das três zonas, ou seja, assim como apontado na figura 1, cada amostra de campo recebeu sua classe conforme a sua zona de alocação. A PCA também foi utilizada para eliminar variáveis multicolineares e covariantes, que, além de reduzir o número de variáveis envolvidas, remove variáveis/amostras que podem proporcionar erros de interpretação do conjunto. Também foram eliminadas amostras e variáveis que foram consideradas discrepantes pelo teste de Distância de Mahalanobs e aquelas que apresentaram poder de modelamento da PCA abaixo de 0,30. Após a análise preliminar do conjunto de dados pela PCA, no conjunto final de dados resultante desta última, foi aplicada a SIMCA se utilizando os mesmos métodos de pré-processamento da PCA. A Tabela 1, apresenta o teste de validação do método de estimativa para a geração do mapa de Zonas de Potencial Produtivo em relação aos grupos de amostras de solo pré-definidos de acordo com o zoneamento de amostragem. Nesse teste da SIMCA a analise testa o enquadramento de cada amostra em relação as classes existentes/cadastradas pelo analista no conjunto de dados, que neste caso específico são as três Zonas de Potencial Produtivo, referenciado no texto como classe nominal. A linha *Best*, apresenta a classe no qual o modelo analítico considera como melhor enquadramento em relação as classes existentes onde, o número 1 representa a classe 1 (alto potencial produtivo), 2 (potencial médio), 3 (baixo potencial) e zero (0) representa que a amostra não se enquadra em nenhuma das classes nominais pré-cadastradas. A coluna *Next Best*, se refere a classe, em ordem decrescente, no qual o modelo sugere que cada amostra pode ser reenquadrada ou a amostra está muito próxima.

TABELA 1. Predição analítica de enquadramento das amostras com base nas três classes (Zonas de Potencial Produtivo) no qual cada amostra se enquadra (Best) e qual outra classe a referida amostra poderia ser realocada (Next Best).

Amostra em relação ao local / zoneamento de coleta	Zonas de Potencial Produtivo																					
	Alto (classe 1)							Médio (classe 2)							Baixo (classe 3)							
Número da Amostra	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	
Nominal	1	1	1	1	1	1	1	2	2	2	2	2	2	2	3	3	3	3	3	3	3	
Best (classe)	1	1	1	1	1	1	1	2	2	2	2	2	2	2	3	3	3	3	3	3	3	
Next Best (classe)	0	0	0	0	0	0	3	1	3	1	3	3	3	3	1	0	0	0	0	0	0	

De acordo com a Tabela 1, todas as amostras se enquadram nas suas respectivas classes nominais, no qual todas as amostras de 1 a 7, pertencem a classe 1 (zona de alto potencial), conforme estimado pela metodologia testada. As todas as amostras de 8 a 14 pertencem à classe 2 ou zona de potencial médio normal e, todas as amostras de 15 a 21 pertencem a classe 3, ou zona de baixo potencial produtivo, a 95% de probabilidade de erro probabilístico. Ainda, é possível observar que o modelo de teste preditivo também indica que existem amostras que estão em uma zona de transição, apresentado pela classificação *Next Best*, no qual fica bem característico que a zona de médio potencial produtivo está claramente em transição entre a classe da zona de baixo potencial produtivo e a de alto potencial, como se pode observar no caso das amostras 9, 11, 12, 13 e 14, as quais estão em uma transição entre a classe 2 e 3, o que faz muito sentido para esta zona, visto ser uma região estatisticamente intermediaria. Continuando a interpretação das saídas da SIMCA, na Tabela 2, apresenta o resultado da *Misclassification*, que é uma análise de auto validação dos modelos, a qual verifica possíveis amostras classificadas erroneamente pela análise de enquadramento da Tabela 1. Na Tabela 2 a identificação de valores numéricos diferentes de zero fora da diagonal da tabela, indicam que o modelo pode ter errado o enquadramento de classe de alguma das amostras. O número 7 apresentado para as classes nominais em relação as preditoras, representam o número total de amostras enquadradas corretamente em sua respectiva classe analítica. Sobre a coluna não correspondência (*No Match*), a existência de qualquer número diferente de zero indica a presença de amostras que não se enquadram em nenhuma das classes nominais e nem das preditoras geradas pelo modelo de acordo com o conjunto de dados.

TABELA 2. Modelo de validação quantitativa do enquadramento das amostras nas classes nominais e preditoras do modelo analítico Misclassification.

Zonas de potencial produtivo	Preditora da classe 1	Preditora da classe 2	Preditora da classe 3	Amostras sem correspondência (*no match*)
Alto (classe nominal 1)	7	0	0	0
Médio (classe nominal 2)	0	7	0	0
Baixo (classe nominal 3)	0	0	7	0

A partir do resultado obtido pelos modelos de autoavaliação da SIMCA, é possível reconhecer que a metodologia proposta por Santos et al. (2023) apresenta relação direta e indireta com as variáveis de solo testadas dentro dos modelos de escalonamento multidimensional, com uma probabilidade de erro 5%. Assim se pode afirmar que a metodologia de segregação em três zonas de potencial produtivo através da análise da variação intrínseca dos dados de produtividade advindos de monitor de colheita, é eficiente na geração de zonas com comportamento de variação homogêneo, permitindo se

identificar de forma objetiva os locais para a realização de amostragem de variáveis de solo, reduzindo o número de pontos amostrais sem a perda de informações importantes, e permitindo uma informação de saída mais simplificada (somente três classificações). Ainda, visto a menor necessidade número de amostragens, o técnico ou o engenheiro pode expandir os tipos de analise, não se limitando apenas ao analise físico química do solo. Ainda como desdobramento da SIMCA para este estudo de caso, é possível observar que as variáveis que apresentaram maior poder de modelamento estão ligadas a estrutura do solo e a movimentação de água e ar, sendo as variáveis de macro porosidade (MacPor30 e MacPor50) e porosidade total calculada (PTc) as que apresentaram maior poder de modelamento, conforme a Figura 2.

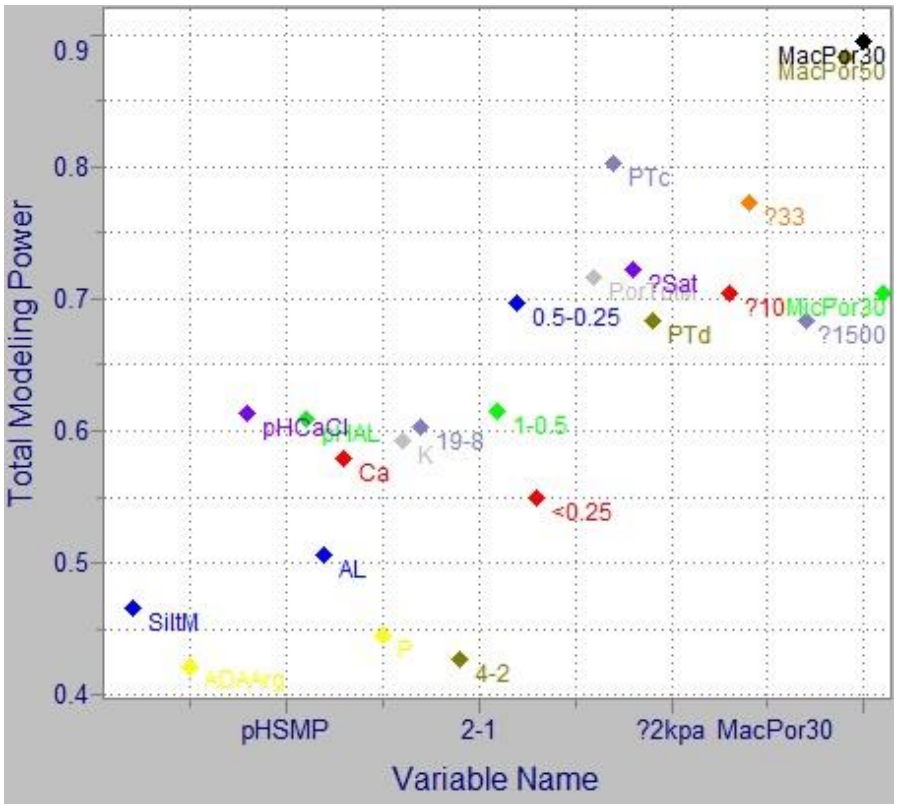


FIGURA 2. Disposição gráfica do poder de modelamento das variáveis para a estimativa geral das classes nominais da SIMCA.

CONCLUSÃO

A avaliação das relações entre o mapa de zonas de potencial produtivo proposto por Santos et al. (2023) com as variáveis de solo apresentou grau de relação de 84,5% a 5% de probabilidade de erro.

Para este estudo de caso, a metodologia se apresentou eficiente quanto a geração das zonas de potencial produtivo homogêneas, visando a determinação de pontos para amostragem de solo no campo e para a realização de inferência estatística e técnica sobre o comportamento da variação intrínseca da área, quanto a resposta à produtividade das culturas em relação ao manejo, possibilitando intervenções mais assertivas.

Visto o elevado grau de relação das zonas de potencial produtivo com as variáveis de solo, se considera que é possível substituir a amostragem em grade pela alocação especifica de acordo com as três zonas de potencial produtivo, permitindo uma amostragem direcionada e em menor número, sem a perda de informações relevantes da área.

Neste estudo de caso, se obteve que as variáveis com maior poder de modelamento estão ligadas a estrutura do solo e a movimentação de água e ar, portanto, os levantamentos de campo não devem se restringir a amostragem para análise físico-química.

AGRADECIMENTOS

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela bolsa de estudos; ao Instituto de Desenvolvimento Rural do Paraná IAPAR-Emater (IDR-Paraná), Área de Engenharia Agrícola e Tecnologias Digitais pela concessão da metodologia estudada e apresentada; ao Vinicius Andrade Favoni e família, proprietários da área de estudo e concedentes dos dados aplicados neste trabalho.

REFERÊNCIAS

AGUIAR, P. A. A. Padronização da umidade dos grãos na experimentação agrícola. In: Embrapa Semiárido-Resumo em **anais de congresso** (ALICE). In: EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. Centro de Pesquisa Agropecuária do Trópico Semi-Árido. Petrolina. Resumo de atividades de pesquisa. Petrolina, 1977.

CHLINGARYAN, A.; SUKKARIEH, S., WHELAN, B. Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: A review, **Computers and Electronics in Agriculture,** v. 151, p. 61-69, 2018. https://doi.org/10.1016/j.compag.2018.05.012.

KÖPPEN, W. P. Grundriss der klimakunde. W. de Gruyter, 1931.

OLIVEIRA, M. T., SARAIVA, A. **Fundamentos de geodesia e cartografia**. Porto Alegre: Bookman editora, 2015

PATHAK, H. S., BROWN, P., BEST, T. Adoption barriers for precision agriculture technologies in Canadian crop production. **Precision Agriculture,** v.20, p.1292 - 1316. 2019. https://doi.org/10.1139/cjps-2020-0234.

ROBERTS, D. P.; MATTOO, A. K. Sistemas sustentáveis de produção de culturas e nutrição humana. **Frontiers in Sustainable Food Systems**, v. 3, p. 72, 2019. https://doi.org/10.3389/fsufs.2019.00072.

SANTOS, L. M. G., SAAB, O. J. G. A., GUIMARÃES, M. D. F., RALISCH, R., & DELALIBERA, H. C. Methodology for estimating productive potential zones from productivity data. **Semina: Ciênc. Agrár**, v. 44, n. 3, p. 1001 - 1016. 2023. Doi: 10.5433/1679-0359.2022v44n3p1001.

SOUZA, E. G., BAZZI, C. L., KHOSLA, R., URIBE-OPAZO, M. A., REICH, R. M. Interpolation type and data computation of crop yield maps is important for precision crop production, **Journal of Plant Nutrition,** v. 39, n. 4, p. 531 - 538, 2016. https://doi.org/10.1080/01904167.2015.1124893.

WACHOWIAK, M. P., WALTERS, D. F., KOVACS, J. M., WACHOWIAK-SMOLÍKOVÁ, R., JAMES, A. L. Visual analytics and remote sensing imagery to support community-based research for precision agriculture in emerging áreas. **Computers and Electronics in Agriculture**. V. 143, 2017. https://doi.org/10.1016/j.compag.2017.09.035.

ESCOLHA DO MELHOR MODELO DE APRENDIZADO DE MÁQUINA PARA A CLASSIFICAÇÃO DE SOLOS ARGILOSOS E ARENOSOS COM BASE EM IMAGENS

Gustavo Di Chiacchio Faulin [1]; Pedro Shuichi Hirata [2]; Thayna Lima Carvalho [2]; Marco António Ludovico Marques [3]; Marisa Silveira Almeida Renaud Faulin [1]

[1]Docente. Av. Fundação Shunji Nishimura de Tecnologia, 605, Pompeia, SP. Fatec Pompeia Shunji Nishimura; [2]Tecnólogo. Av. Fundação Shunji Nishimura de Tecnologia, 605, Pompeia, SP. Fatec Pompeia Shunji Nishimura; [3]Docente. Rua Américo da Silva Marinho, Barreiro, Portugal. Escola Superior de Tecnologia do Barreiro

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A distribuição do tamanho das partículas do solo é tradicionalmente analisada por meio de métodos de peneiramento e sedimentação, que envolvem custos relativamente baixos, embora sejam tediosos e demorados. Determinar a textura do solo a partir da distribuição do tamanho das partículas é de grande importância no manejo agrícola e em programas de seguro rural. O objetivo deste estudo foi identificar o melhor modelo de aprendizado de máquina para classificar solos em texturas Arenosa, Argilosa e Muito Argilosa a partir de imagens. Para isso, foi compilado um banco de dados composto por 660 imagens, com 220 imagens para cada classe textural. As imagens foram capturadas por um microscópio digital com resolução de 16 megapixels e ampliação de até 1.300 vezes. O modelo SqueezeNet foi utilizado para extrair descritores das imagens. O conjunto de dados foi dividido em conjuntos de treinamento e teste usando uma proporção de divisão de 80/20, respectivamente. Foram avaliados modelos de aprendizado de máquina, incluindo k-Nearest Neighbors (kNN), Regressão Logística, Support Vector Machine (SVM), Árvore de Decisão, Random Forest (RF) e Rede Neural Artificial. O modelo SVM apresentou o melhor desempenho e foi selecionado para análise da matriz de confusão, que revelou uma alta taxa de precisão na classificação de amostras de solo Arenoso. No entanto, foram observados erros na distinção entre as classes Argilosa e Muito Argilosa.

PALAVRAS-CHAVE: análise de imagens; classificação textural; física do solo

ABSTRACT

Soil particle size distribution is traditionally analyzed through sieving and sedimentation methods, which entail relatively low costs, albeit being tedious and time-consuming procedures. Determining soil texture from particle size distribution is of great importance in agricultural management and rural insurance programs. The aim of this study was to identify the best machine learning model to classify soils into Sandy, Clayey, and Very Clayey textures from images. To achieve this, a database comprising 660 images was compiled, with 220 images for each textural class. The images were captured using a digital microscope with a resolution of 16 megapixels and magnification of up to 1,300 times. The SqueezeNet model was employed to extract descriptors from the images. The data set was divided into training and testing sets using an 80/20 split ratio, respectively. Machine learning models including k-Nearest Neighbors (kNN), Logistic Regression, Support Vector Machine (SVM), Decision Tree, Random Forest (RF), and Artificial Neural Network were evaluated. The SVM model exhibited the best performance and was selected for confusion matrix analysis, which revealed a high precision rate in classifying Sandy soil samples. However, errors were observed in distinguishing between Clayey and Very Clayey classes.

KEYWORDS: ;;

INTRODUÇÃO

As propriedades físicas do solo são importantes indicadores da qualidade e da capacidade de produção dos solos agrícolas. A textura é a propriedade física que está relacionada às partículas primárias como argila, silte e areia e a sensação de tato como sedosidade, atrito e pegajosidade (BERTONI; LOMBARDI NETO, 2017). A textura como um importante indicador da qualidade física do solo, possibilita compreender algumas interações como a ciclagem de nutrientes, troca de íons, resistência à tração, a dinâmica da água, contribuindo para o crescimento das plantas, como mostram os trabalhos de Centeno et al., 2017 e Klein et al., 2010. A porcentagem das partículas de argila, silte e areia, que é definida pelos seus diferentes diâmetros, é chamada de granulometria. A granulometria auxilia na identificação da classificação textural, que é a separação em grupos, sendo possível determinar o tipo de textura através do emprego dos triângulos texturais (KLEIN, 2014). Assim, identificar a textura do solo por meio da mensuração de sua granulometria é importante para planejar as estratégias que serão adotadas no manejo da produção buscando otimizar seus recursos e conservar os solos agrícolas. Pensando em uma solução para agilizar o processo de análise granulométrica nos laboratórios de solo ou propor técnicas de análise e recomendações que poderão ser realizadas pelo próprio agricultor, propõe-se a utilização da aprendizagem de máquina na identificação das classes texturais a partir de imagens do solo como uma alternativa interessante, principalmente se bons resultados puderem ser obtidos utilizando uma câmera. Algumas pesquisas trazem resultados relevantes no uso da aprendizagem de máquina em estudos com solo lunar e de planetas, já que nesses casos o imageamento é muito utilizado. A utilização de técnicas de aprendizagem de máquina com imagem do solo é descrita em diversas pesquisas e têm se mostrado promissoras na determinação das propriedades físicas e mineralógicas usando espectros de refletância em solo marciano (LIRA; SARAIVA; PINA, 2010), na identificação rápida da distribuição do tamanho dos grãos em solos granulares (ZHANG et al., 2021), na classificação de solos lunares com base em seus tipos, tamanho de partícula, maturidade e tipo de piroxênio (KODIKARA; MCHENRY, 2020), tendo o potencial de fornecer análises precisas e eficientes das propriedades do solo, auxiliando no mapeamento e gerenciamento do solo (SWETA et al., 2022).

OBJETIVOS

O objetivo desse trabalho foi identificar o melhor algoritmo de aprendizado de máquina para a classificação de imagens de solo nas texturas Arenosa, Argilosa e Muito Argilosa.

MATERIAL E MÉTODOS

Foram selecionadas sessenta e seis amostras de solo de diversas regiões do Brasil, distribuídas igualmente entre três classes texturais: Arenosa, Argilosa e Muito Argilosa, com base nas frações granulométricas de areia, silte e argila determinadas pelo método da pipeta (DONAGEMMA et al., 2017). Estas amostras foram fornecidas pelo Laboratório de Solos e Tecido Vegetal da Fundação Shunji Nishimura de Tecnologia. Cada amostra foi seca e homogeneizada a fim de eliminar qualquer sedimentação. Na sequência foram transferidas para placas de Petri de dimensões 60 x 15 mm, assegurando um nivelamento adequado da superfície para evitar desfoque nas imagens (Figura 1a). As imagens foram capturadas utilizando um microscópio digital da marca MOYSUWE, modelo MDM201 Pro (Figura 1b), que oferece uma capacidade de ampliação máxima de até 1.300 vezes e uma resolução de 16 megapixels.



(a) (b)

FIGURA 1. (a) Processo de nivelamento da superfície da amostra na placa de Petri; (b) Microscópio digital com ampliação de 1.300 vezes e resolução de 16 megapixels.

Com a capacidade de ampliação do microscópio, tornou-se viável a captura de imagens de cada amostra em dez diferentes posições da superfície, resultando em 10 imagens por amostra. Isso totalizou 220 imagens para cada classe textural, considerando as 22 amostras por classe. A ampliação da imagem foi ajustada de acordo com a altura da lente focal da câmera do microscópio, a fim de evitar o desfoque em regiões da imagem devido às disparidades nos tamanhos dos agregados. Para determinar o modelo de aprendizado de máquina que apresenta melhor desempenho na classificação das imagens de solo em Arenosa, Argilosa e Muito Argilosa, utilizou-se o software Orange versão 3.36.2 (DEM?AR et al., 2013). O modelo adotado para gerar os vetores descritores das imagens foi o SqueezeNet com processamento local. Durante a etapa de treinamento do modelo, 80% das imagens foram selecionadas aleatoriamente para treinamento, enquanto 20% foram reservadas para teste, totalizando respectivamente 176 e 44 imagens. Os modelos de aprendizado de máquina supervisionados escolhidos incluíram k-Nearest Neighbors (kNN), Regressão Logística, Support Vector Machine (SVM), Árvore de Decisão, Random Forest (RF) e Rede Neural Artificial. Ademais, o modelo Constante foi adotado como referência para avaliação, servindo como base comparativa. Para selecionar o melhor modelo, foram calculados e analisados os parâmetros Área sob a Curva (AUC), Acurácia, Precisão, Revocação, F1-Score e Coeficiente de Correlação de Matthews (MCC). O parâmetro AUC, representando a Área sob a Curva ROC, avaliou a capacidade de classificação das classes pelo modelo. A Acurácia quantificou o percentual de classificações corretas, refletindo a eficácia geral do modelo. A Precisão mediu a proporção de verdadeiros positivos entre os casos classificados como positivos, enquanto a Revocação (ou Recall) indicou a proporção de verdadeiros positivos corretamente identificados em relação ao total de positivos. O F1-Score, uma média harmônica entre Precisão e Revocação, proporcionou uma visão equilibrada da performance. O MCC, considerando verdadeiros e falsos positivos e negativos, foi utilizado como medida equilibrada para avaliar o desempenho dos modelos, especialmente em conjuntos de dados desbalanceados. Após a escolha do modelo que melhor performou, foi gerada a matriz de confusão para avaliar o desempenho do modelo na tarefa de classificação dos solos Arenosos, Argilosos e Muito Argilosos.

RESULTADOS E DISCUSSÃO

Utilizando o software Orange (DEM?AR et al., 2013) foi possível realizar a avaliação dos modelos de aprendizado de máquina supervisionados k-Nearest Neighbords (kNN), Regressão Logística, Support Vector Machine (SVM), Árvore de Decisão, Random Forest (RF) e Rede Neural Artificial na identificação da classe textural em imagens de amostras de solo. Como parâmetro base foi utilizado o modelo Constante que é útil para estabelecer a linha de base para a avaliação dos modelos mais complexos. Se um modelo mais complexo não conseguir superar o desempenho do modelo Constante, sugere que algo está errado e que é necessário revisar o modelo ou o conjunto de dados. Na Tabela 1 pode ser observado que todos os modelos foram superiores ao modelo Constante.

TABELA 1. Parâmetros dos algoritmos supervisionados de aprendizado de máquina utilizados na classificação de imagens de solo para classificação das texturas arenosas, argilosas e muito argilosas.

Modelo	**AUC**	**Acurácia**	**Precisão**	**Revocação**	**F1- Score**	**MCC**
SVM	0,915	0,780	0,776	0,780	0,778	0,671
Rede Neural Artificial	0,901	0,762	0,757	0,762	0,759	0,643
Regressão Logística	0,905	0,760	0,758	0,760	0,759	0,640
kNN	0,878	0,745	0,738	0,745	0,741	0,618
Random Forest (RF)	0,863	0,715	0,711	0,715	0,713	0,573
Árvore de Decisão	0,740	0,673	0,672	0,673	0,672	0,510
Constante	0,460	0,299	0,299	0,299	0,296	-0,050

AUC: Área sob a Curva ROC (acrônimo do inglês, Característica de Operação do Receptor); MCC: Coeficiente de Correlação de Matthews

O modelo SVM superou os demais em todos os parâmetros e se mostrou o mais adequado para a classificação das imagens de solo nas texturas Arenosas, Argilosas e Muito Argilosas. Todos os modelos testados ficaram acima do modelo Constante. A Tabela 2 demonstra a matriz de confusão para o modelo SVM na classificação das imagens.

TABELA 2. Matriz de confusão para o modelo Support Vector Machine (SVM) na classificação de imagens de solo em Arenosa, Argilosa e Muito Argilosa.

Matriz de confusão do Modelo Supervisionado SVM				
		Classe Textural - Predita		
		Arenosa	**Argilosa**	**Muito Argilosa**
Classe Textural Atual	**Arenosa**	200 91,1%	6 2,6%	0 0,0%
	Argilosa	17 7,6%	153 69,4%	65 29,4%
	Muito Argilosa	3 1,3%	61 28,0%	155 70,6%

A análise da matriz de confusão revela que, embora o modelo SVM apresente indicadores superiores em comparação com os outros algoritmos, persiste uma ambiguidade na classificação das classes Argilosa e Muito Argilosa. Para a categoria Arenosa, das 220 imagens, 200 foram corretamente classificadas como Arenosa, 17 classificadas como Argilosa e apenas 3 como Muito Argilosa. Para a classe Argilosa, das 220 imagens, o algoritmo classificou erroneamente 6 imagens como Arenosa,

153 corretamente como Argilosa e 61 erroneamente como Muito Argilosa. Em relação as 220 imagens da classe Muito Argilosa, o modelo se comportou muito próximo as classificações para os solos Argilosos, com 65 amostras classificadas de forma errônea como Argilosa e 155 imagens corretamente classificadas como Muito Argilosa. As porcentagens de acerto para as classes Argilosa e Muito Argilosa ficaram próximas a 70%. Estudos adicionais estão em andamento para explorar novos parâmetros, visando aprimorar a acurácia na classificação das classes texturais, especialmente entre as classes Argilosa e Muito Argilosa.

CONCLUSÃO

Entre os modelos testados, o Support Vector Machine (SVM) obteve o melhor desempenho evidenciado pelos parâmetros de avaliação. A análise da matriz de confusão para o modelo SVM revelou uma alta taxa de precisão na classificação das amostras de solo Arenosa, porém, persistiram desafios na distinção entre as classes Argilosa e Muito Argilosa. Houve uma certa ambiguidade, com uma proporção significativa de amostras sendo erroneamente classificadas entre essas duas classes. Diante disso, sugerimos que estudos adicionais sejam conduzidos para explorar novos parâmetros e técnicas de aprendizado de máquina, visando aprimorar a acurácia na classificação das classes texturais de solo, especialmente entre as classes Argilosa e Muito Argilosa.

AGRADECIMENTOS

Ao Laboratório de Solos e Tecido Vegetal da Fundação Shunji Nishimura de Tecnologia pela concessão das amostras e análises granulométricas.

REFERÊNCIAS

BERTONI, José; LOMBARDI NETO, Francisco. **Conservação do solo**. 10. ed. São Paulo: Editora Ícone, 2017.

CENTENO, Luana Nunes; GUEVARA, Miguel David Fuentes; CECCONELLO, Samanta Tolentino; SOUSA, Rogério Oliveira De; TIMM, Luís Carlos. TEXTURA DO SOLO: CONCEITOS E APLICAÇÕES EM SOLOS ARENOSOS. **Revista Brasileira de Engenharia e Sustentabilidade**, *[S. l.]*, v. 4, n. 1, p. 31-37, 2017. DOI: 10.15210/RBES.V4I1.11576. Disponível em: https://periodicos.ufpel.edu.br/index.php/ RBES/article/view/11576. Acesso em: 28 set. 2023.

DEM?AR, Janez et al. Orange: Data Mining Toolbox in Python. **Journal of Machine Learning Research**, *[S. l.]*, v. 14, p. 2349-2353, 2013. Disponível em: http://jmlr.org/papers/v14/demsar13a.html.

DONAGEMMA, Guilherme Kangussu; VIANA, João Herbert Moreira; ALMEIDA, Brivaldo Gomes De; RUIZ, Hugo Alberto; KLEIN, Vilson Antônio; DECHEN, Sonia Carmela Falci; FERNANDES, Raphael Bragança Alves. Análise granulométrica. *In*: TEIXEIRA, Paulo César; DONAGEMMA, Guilherme Kangussu; FONTANA, Ademir; TEIXEIRA, Wenceslau Geraldes (org.). **Manual de métodos de análise de solo**. 3ª ed. Brasília, DF: Embrapa, 2017. p. 573. Disponível em: https://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/1087262. Acesso em: 30 set. 2022.

KLEIN, Vilson Antonio. **Física do solo**. 3. ed. Passo Fundo: UPF, 2014.

KLEIN, Vilson Antonio; BASEGGIO, Matheus; MADALOSSO, Tiago; MARCOLIN, Clóvis Darli. Textura do solo e a estimativa do teor de água no ponto de murcha permanente com psicrômetro. **Ciência Rural**, *[S. l.]*, v. 40, n. 7, p. 1550-1556, 2010. DOI: 10.1590/S0103-

84782010005000110. Disponível em: https://www.scielo.br/j/cr/a/kVB7wXkns8bdbHVP7LcCJPP/?lang=pt. Acesso em: 28 set. 2023.

KODIKARA, Gayantha R. L.; MCHENRY, Lindsay J. Machine learning approaches for classifying lunar soils. **Icarus**, *[S. l.]*, v. 345, p. 113719, 2020. DOI: 10.1016/J.ICARUS.2020.113719.

LIRA, C.; SARAIVA, J.; PINA, P. Full Granulometric Curves of Meridiani Soils. *In*: 41ST LUNAR AND PLANETARY SCIENCE CONFERENCE 2010, Houston. **Anais** [...]. Houston: Lunar and Planetary Institute, 2010. p. Abstract \#2043. Disponível em: https://www.lpi.usra.edu/meetings/lpsc2010/pdf/2043.pdf.

SWETA, Kumari; DHARUMARAJAN, S.; SUPUTHRA, Amar; LALITHA, M.; VASUNDHARA, R.; KALAISELVI, B.; KUMAR, B. N. Shashi; SATHISH, A.; HEGDE, Rajendra. Transforming Soil Paradigms with Machine Learning. *[S. l.]*, p. 243-265, 2022. DOI: 10.1007/978-981-16-5847-1_12. Disponível em: https://link.springer.com/chapter/10.1007/978-981-16-5847-1_12. Acesso em: 28 set. 2023.

ZHANG, Pin; YIN, Zhen-Yu; CHEN, Wen-Bo; JIN, Yin-Fu. CNN-Based Intelligent Method for Identifying GSD of Granular Soils. **International Journal of Geomechanics**, *[S. l.]*, v. 21, n. 12, p. 04021229, 2021. DOI: 10.1061/(ASCE)GM.1943-5622.0002214/ASSET/6ECEBB91-B2E3-4C57-B3EE-4CC88ED70361/ ASSETS/IMAGES/LARGE/GMENG-6620F10.JPG. Disponível em: https://ascelibrary.org/doi/abs/ 10.1061/%28ASCE%29GM.1943-5622.0002214. Acesso em: 28 set. 2023.

DADOS GEOESPACIAS APLICADOS A AVALIAÇÃO DE PERDA DE SOLO

LAYANE CARMEM ARRUDA DA ROCHA [2]; MAYKON RODRIGO GOMES DE BARROS [1]; MICHEL CASTRO MOREIRA [3]; RICARDO SANTOS SILVA AMORIM [3]

[1]Doutorando. Gurupi -TO. Universidade Federal de Tocantins; [2]Doutoranda. Viçosa - MG. Universidade Federal de Viçosa; [3]Docente. Viçosa - MG. Universidade Federal de Viçosa

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A erosão do solo tem um impacto negativo significativo no setor agrícola, resultando em áreas inadequadas para o cultivo. Nesse contexto, a modelagem tornou-se uma ferramenta indispensável para estimar diversos fatores, incluindo a perda de solo. Com essas estimativas, é possível desenvolver estratégias para mitigar os fatores que contribuem para a erosão. Entre os modelos consolidados, destacam-se o WEPP (Water Erosion Prediction Project) e, em nível de bacia hidrográfica, o GeoWEPP. Ambas as ferramentas têm se mostrado eficazes na gestão de bacias hidrográficas em diversos países. O objetivo deste trabalho foi avaliar a aplicação do modelo GeoWEPP para estimar a perda de solo em duas sub-bacias hidrográficas do bioma amazônico. Observou-se que a menor perda de solo ocorreu em áreas mais planas com vegetação nativa, enquanto as maiores perdas foram registradas em regiões com pastagem degradada. O GeoWEPP demonstrou ser uma ferramenta valiosa para a estimativa da perda de solo, permitindo a formulação de estratégias de mitigação a partir dos dados obtidos.

PALAVRAS-CHAVE: Geowepp; Modelagem; Conservação

ABSTRACT

Soil erosion has a significant negative impact on the agricultural sector, resulting in areas unsuitable for cultivation. In this context, modeling has become an indispensable tool for estimating several factors, including soil loss. With these estimates, it is possible to develop strategies to mitigate the factors that contribute to erosion. Among the consolidated models, the WEPP (Water Erosion Prediction Project) and, at the watershed level, GeoWEPP stand out. Both tools have proven effective in watershed management in several countries. The objective of this study was to evaluate the application of the GeoWEPP model to estimate soil loss in two sub-watersheds of the Amazon biome. It was observed that the lowest soil loss occurred in flatter areas with native vegetation, while the greatest losses were recorded in regions with degraded pasture. GeoWEPP proved to be a valuable tool for estimating soil loss, allowing the formulation of mitigation strategies based on the data obtained.

KEYWORDS: Geowepp; Modeling; Conservation

INTRODUÇÃO

A erosão hídrica do solo representa uma ameaça significativa para a agricultura, pois, quando intensificada, pode levar a depleções irreversíveis na qualidade do solo (BEZAK et al., 2021; GRAHMANN et al., 2022). Com o aprimoramento dos dados geoespacializados, diversos estudos têm sido realizados para compreender o comportamento do solo em relação a diferentes parâmetros edafoclimáticos, o que apoia o planejamento de medidas adequadas de proteção do solo. A literatura aponta que modelos físicos são mais precisos, pois permitem a inclusão de diversos parâmetros e fenômenos complexos (TRIPATHY, MISHRA, 2024; HAJIGHOLIZADEH et al., 2018). Entre eles, destaca-se o GeoWEPP (Geospatial Water Erosion Prediction Project), um modelo que combina o

WEPP com Sistemas de Informação Geográfica, como ArcGIS ou QGIS (LUETZENBURG et al., 2020; NERIS et al., 2021). Esse modelo possibilita a consideração de processos complexos que influenciam a perda de solo, configurando-se como uma ferramenta valiosa para a formulação de estratégias de uso e manejo do solo que favoreçam a conservação tanto do solo quanto da água em nível de bacias hidrográficas (RENSCHLER; ZHANG, 2020; REZA MEGHDADI, 2013).

OBJETIVOS

Avaliar a aplicação do modelo GEOWEPP para estimativa da perda de solo, para duas sub-bacias hidrográficas do bioma amazônia.

MATERIAL E MÉTODOS

A região de estudo abrange as áreas de drenagem das estações fluviométricas 27550000 (Arapoema) e 30075000 (Tartarugal Grande), localizadas no bioma Amazônico. Os solos predominantes na área incluem Latossolos Vermelho Distrófico (LVd), Latossolos Vermelho-Amarelo Distrófico (LVAd), Argissolo Amarelo Distrófico (PAd), Argissolo Vermelho-Amarelo Distrófico (PVAd), Neossolo Litólico Distrófico (RLd) e Neossolo Quartzarênico Órtico (RQo). Para a modelagem, foi necessário criar arquivos de entrada que identificassem parâmetros como textura (% de areia e argila), matéria orgânica (%), capacidade de troca catiônica (meq/1) e pedregosidade (%), considerando cada perfil do solo. A obtenção desses parâmetros foi realizada a partir da plataforma BDsolos (EMBRAPA, 2022), filtrando pela classificação do solo e pela localização (estado brasileiro). Além desses parâmetros, o arquivo exigiu mais seis informações: saturação inicial, albedo, erodibilidade entre sulcos, tensão crítica de cisalhamento e condutividade hidráulica efetiva superficial do solo. A saturação inicial foi obtida também do BDsolos, enquanto o albedo foi mantido no valor padrão fornecido pelo WEPP, que é 0,23, conforme sugerido por Poeppl et al. (2019). Os parâmetros de erodibilidade, tensão crítica de cisalhamento e condutividade hidráulica efetiva do solo superficial foram calculados pelo modelo WEPP, utilizando algoritmos de estimativa de parâmetros com base na base de dados WEPP. Essa abordagem é necessária, pois os valores variam de acordo com a textura, uso e manejo do solo (CANTALICE et al., 2005; MESQUITA; MORAES, 2004; MONTENEGRO; MONTENEGRO, 2006; SANTOS et al., 2018). Para caracterizar o uso e ocupação do solo, foram utilizados dados do projeto MapBiomas - coleção 6 (MAPBIOMAS, 2022). Os rasteres gerados permitiram identificar a utilização da terra ao longo dos anos, e para cada ano modelado, foi utilizado o raster correspondente. Adicionalmente, o WEPP conta com arquivos de uso e ocupação do solo em sua interface, baseados em parâmetros de crescimento e mortalidade das plantas. Como não havia informações precisas sobre as condições culturais da área em estudo (como período de cultivo e tamanho das raízes), foi utilizado o banco de dados do WEPP, associando os dados de uso e ocupação obtidos no MapBiomas ao banco de dados disponível na interface do software. Para determinar qual categoria do WEPP se associaria às categorias brasileiras, seguiram-se as recomendações do site e manual do GEOWEPP (HAOYI et al., 2014), além de trabalhos publicados que utilizaram essa ferramenta, como os de Leite (2009), Melaku et al. (2018) e Poeppl et al. (2019).

RESULTADOS E DISCUSSÃO

De maneira geral, embora ambas as sub-bacias estejam localizadas no bioma amazônico, a sub-bacia do rio Tartarugal é predominantemente coberta por áreas florestais, enquanto a sub-bacia do rio Jenipapo é caracterizada por uma maior presença de áreas agrícolas. A distribuição espacial da perda de solo, estimada pelo modelo GeoWEPP, pode ser observada na Figura 1, que também ilustra a relação entre a perda de solo e a precipitação pluviométrica nos anos analisados.

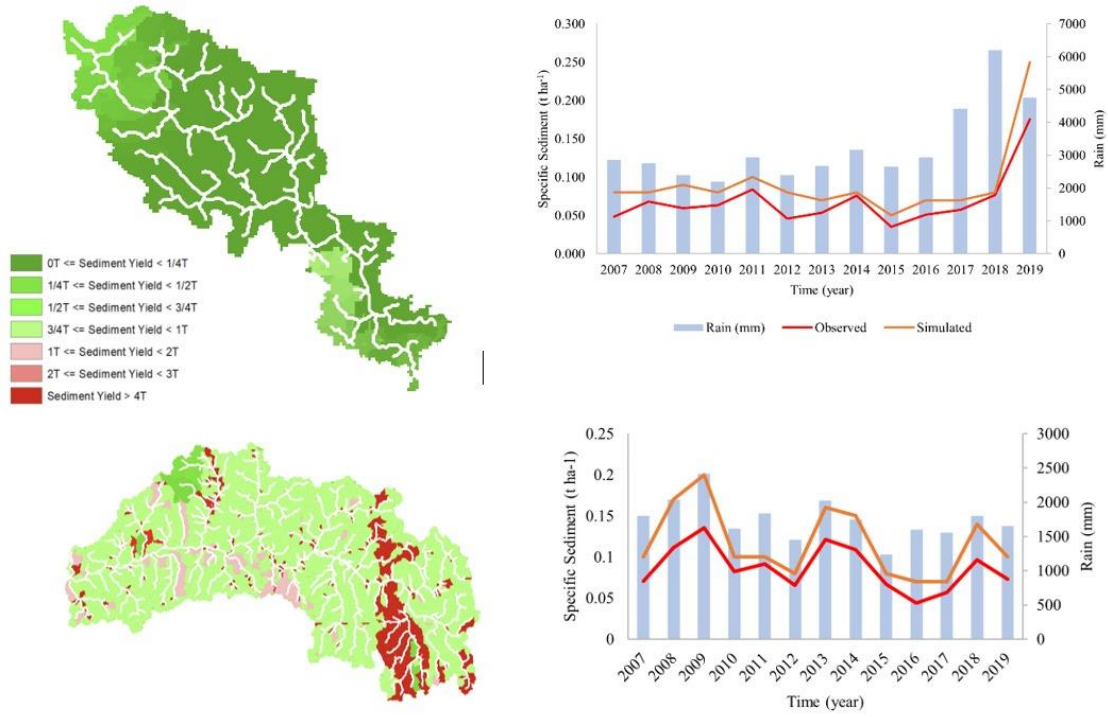


FIGURA 1. Distribuição espacial da perda de solo e variação entre os anos analisados

Na sub-bacia do rio Tartarugal, a perda de solo (PS) apresenta uma certa uniformidade ao longo de sua área, variando entre 0 e 3/4T. As regiões com maior perda de solo coincidem com a transição entre Latossolos e Argissolos. Contudo, ao analisarmos os dados, constatamos que essa diferença é insignificante para o modelo. Avaliando a PS ao longo dos anos, observamos que ela acompanha os padrões de precipitação. Em 2018, o total acumulado de chuva foi de 6192,3 mm, com o maior volume registrado em dezembro. Em 2019, a chuva acumulada atingiu 4763,3 mm, sendo 818,5 mm apenas em janeiro. O aumento da perda de solo em 2019 pode ser atribuído à intensidade da precipitação, um fator crucial no processo erosivo. Nossos resultados corroboram o que foi destacado por Mohamadi e Kavian (2015) e Pal e Chakrabortty (2019): a precipitação é uma das variáveis dominantes que influencia as tendências de perda de solo. A energia cinética das gotas de chuva contribui para o desprendimento de partículas de solo, resultando na compactação e destruição da estabilidade estrutural dos solos, o que facilita a mobilização das partículas por meio do escoamento superficial (SIEBERS et al., 2023). Na sub-bacia do rio Jenipapo, observamos uma maior variabilidade na perda de solo. A PS foi menor nas áreas onde florestas nativas ainda estão preservadas. Santana et al. (2023) apontam que os solos de florestas nativas tendem a ter maior condutividade hidráulica, o que reduz a suscetibilidade à erosão (FALK et al., 2024). Em contrapartida, as maiores perdas de solo foram registradas em áreas com alta concentração de atividades agrícolas e pastagens, onde predominam os latossolos vermelhos distróficos. Segundo a EMBRAPA (2021), esses solos são fundamentais para a produção de grãos no Brasil, ocorrendo predominantemente em regiões de relevo plano e suavemente ondulado, o que facilita a mecanização agrícola.

CONCLUSÃO

O modelo GeoWEPP demonstrou-se eficaz na avaliação da perda de solo, permitindo a identificação de áreas com maior susceptibilidade à erosão. Essa ferramenta é valiosa para estimar a perda de solo e possibilita o desenvolvimento de estratégias de manejo a partir dos dados obtidos. Embora ambas as bacias estejam localizadas no mesmo bioma, a bacia do rio Jenipapo apresentou uma perda de solo mais acentuada, possivelmente associada à presença de pastagens degradadas.

REFERÊNCIAS

BEZAK, Nejc et al. Soil erosion modelling: A bibliometric analysis. **Environmental Research**, v. 197, p. 111087, 2021. Disponível em: https://doi.org/10.1016/j.envres.2021.111087.

BRASIL. Sistema Nacional de Informações sobre Recursos Hídricos (SNIRH). Série histórica. Disponível em: https://www.snirh.gov.br/hidroweb/serieshistoricas.

CANTALICE, J. R. B. et al. Hidráulica do escoamento e transporte de sedimentos em sulcos em solo franco-argilo-arenoso. **Revista Brasileira de Ciência do Solo**, v. 29, n. 4, p. 597-607, 2005.

CONAB. Progresso de safra. 2024. Disponível em: https://www.conab.gov.br/info-agro/safras/progresso-de-safra?start=90. Acesso em: 4 mar. 2024.

EMBRAPA. Latossolos vermelhos. 2021. Disponível em: https://www.embrapa.br/agencia-de-informacao-tecnologica/tematicas/solos-tropicais/sibcs/chave-do-sibcs/latossolos/latossolos-vermelhos. Acesso em: 30 jun. 2024.

EMBRAPA. Consulta pública - Base de Dados de Solos. Disponível em: https://www.bdsolos.cnptia.embrapa.br/consulta_publica.html. Acesso em: 8 fev. 2024.

FALK, D. et al. Drivers of field-saturated soil hydraulic conductivity: Implications for restoring degraded tropical landscapes. **Science of the Total Environment**, v. 907, 2024. Disponível em: https://doi.org/10.1016/j.scitotenv.2023.168038.

GRAHMANN, K. et al. Soil use legacy as driving factor for soil erosion under conservation agriculture. **Frontiers in Environmental Science**, v. 10, p. 822967, 2022. Disponível em: https://doi.org/10.3389/fenvs.2022.822967.

HAJIGHOLIZADEH, M.; MELESSE, A. M.; FUENTES, H. R. Erosion and sediment transport modelling in shallow waters: A review on approaches, models and applications. **International Journal of Environmental Research and Public Health**, v. 15, p. 518, 2018.

HAONI et al. GeoWEPP ArcGIS 10 Overview. Disponível em: https://fargo.nserl.purdue.edu/geowepp/files/GeoWEPP_ArcGIS10_Overview.pdf. Acesso em: 03 set. 2024.

LEITE-MORAES, A. E. et al. Environmental impacts in integrated production systems: an overview. **Journal of Cleaner Production**, Elsevier Ltd, 25 set. 2023. Disponível em: https://doi.org/10.1016/j.jclepro.2023.138400.

LUETZENBURG, G. et al. Climate and land use change effects on soil erosion in two small agricultural catchment systems Fugnitz - Austria, Can Revull - Spain. **Science of the Total Environment**, v. 704, p. 135389, 2020.

MAPBIOMAS. Coleção 6. 2022. Disponível em: https://mapbiomas.org/.

MELAKU, N. D. et al. Integrated impact assessment of soil and water conservation structures on runoff and sediment yield through measurements and modeling in the Northern Ethiopian highlands. **Catena**, v. 169, n. May, p. 140-150, 2018.

MESQUITA, M. D. G. B. D. F.; MORAES, S. O. A dependência entre a condutividade hidráulica saturada e atributos físicos do solo. **Ciência Rural**, v. 34, n. 4, p. 963-969, 2004.

MONTENEGRO, Abelardo A. A.; MONTENEGRO, Suzana M. G. L. Variabilidade espacial de classes de textura, salinidade e condutividade hidráulica de solos em planície aluvial. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 10, n. 1, p. 30-37, 2006.

MOHAMADI, M. A.; KAVIAN, A. Effects of rainfall patterns on runoff and soil erosion in field plots. **International Soil and Water Conservation Research**, v. 3, n. 4, p. 273-281, dez. 2015.

NERIS, J. et al. Designing tools to predict and mitigate impacts on water quality following the Australian 2019/2020 wildfires: Insights from Sydney's largest water supply catchment. **Integrated Environmental Assessment and Management**, v. 17, n. 1, p. 1-11, 2021.

PAL, S. C.; CHAKRABORTTY, R. Simulating the impact of climate change on soil erosion in sub-tropical monsoon dominated watershed based on RUSLE, SCS runoff and MIROC5 climatic model. **Advances in Space Research**, v. 64, n. 2, p. 352-377, 2019.

POEPPL, Ronald E. et al. Combining soil erosion modeling with connectivity analyses to assess lateral fine sediment input into agricultural streams. **Water (Switzerland)**, v. 11, n. 9, 2019.

RENSCHLER, C. S.; ZHANG, H. Long-term, process-based, continuous simulations for a cluster of six smaller, nested rangeland watersheds near Tombstone, AZ (USA): Establishing a baseline for event-based runoff and sediment yields. **Science of the Total Environment**, v. 717, p. 137089, 2020.

REZA MEGHDADI, A. Identification of effective best management practices in sediment yield diminution using GeoWEPP: The Kasilian watershed case study. **Environmental Monitoring and Assessment**, v. 185, n. 12, p. 9803-9817, 2013.

SANTOS, D. P. DOS et al. Variabilidade espacial de atributos físicos do solo em vale aluvial na região de Pernambuco. **Revista Brasileira de Agricultura Irrigada**, v. 12, n. 1, p. 2271-2282, 2018.

SANTANA, M. L. T. et al. Impacts of land use changes on soil functions and water security: insights from a three-year-long study in the Cantareira System, Southeast of Brazil. **Sustainability (Switzerland)**, v. 15, n. 18, 2023. Disponível em: https://doi.org/10.3390/su151813395.

SANTOS, Daniella Pereira dos et al. Variabilidade espacial de atributos físicos do solo em vale aluvial na região de Pernambuco. **Revista Brasileira de Agricultura Irrigada**, v. 12, n. 1, p. 2271-2282, 2018.

SIEBERS, N. et al. Loss of subsurface particulate and truly dissolved phosphorus during various flow conditions along a tile drain-ditch-brook continuum. **Science of the Total Environment**, v. 866, p. 161439, 2023. Disponível em: https://doi.org/10.1016/j.scitotenv.2023.161439.

TRIPATHY, K. P.; MISHRA, A. K. Deep learning in hydrology and water resources disciplines: concepts, methods, applications, and research directions. **Journal of Hydrology**, v. 622, p. 130458, 2024. Disponível em: https://doi.org/10.1016/j.jhydrol.2023.130458.

ELABORAÇÃO DE MAPAS DE PRODUTIVIDADE EM CITROS

Gabriel Villela Bedum [1]; Mateus Silva Gelain [1]; Eudocio Rafael Otavio da Silva [2]; Ricardo Canal Filho [2]; José Paulo Molin [3]

[1]Graduando em Eng° Agrônomica. Piracicaba-SP. Lab. de Agricultura de Precisão, Depto. Engenharia de Biossistemas, Escola Superior de Agricultura 'Luiz de Queiroz; [2]Doutorando. Piracicaba-SP. Lab. de Agricultura de Precisão, Depto. Engenharia de Biossistemas, Escola Superior de Agricultura 'Luiz de Queiroz; [3]Professor titular. Piracicaba-SP. Lab. de Agricultura de Precisão, Depto. Engenharia de Biossistemas, Escola Superior de Agricultura 'Luiz de Queiroz

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

O Brasil é o maior produtor mundial de laranja, o que evidencia a importância de estudos da variabilidade espacial e temporal da produção para a gestão otimizada e aumento da sustentabilidade do sistema. Este estudo explora uma metodologia já existente de elaboração de mapas de produtividade em citros, integrando processos de filtragem local e técnicas de geoestatística. Para isto, foi utilizada uma série de quatro anos de dados de produtividade em campos comerciais de laranja, tendo como base o georreferenciamento dos sacolões de frutos. Estratégias de filtragem global e local foram investigadas e, posteriormente, foram criados mapas detalhados de produtividade utilizando métodos de espacialização, como polígonos de Voronoi e interpolação probabilística. A metodologia de filtrar os dados de produtividade advindas das áreas de contribuição dos polígonos de Voronoi mostrou-se adequada e permitiu obter mapas que representam informações que auxiliam no planejamento e manejo da produção citrícola. A análise geoestastística revelou dependência espacial moderada para a produtividade, justificando o uso de determinadores probabilísticos, porém a análise temporal dos mapas gerados não apresentou repetibilidade no comportamento produtivo.

PALAVRAS-CHAVE: Geoestatística; Filtragem de dados; Polígono de Voronoi

ABSTRACT

Brazil is the world's largest orange producer, which highlights the importance of studies on spatial and temporal variability of production for optimized management and increased sustainability of the system. This study explores an existing methodology for preparing citrus productivity maps, integrating local filtering processes and geostatistical techniques. For this purpose, a four-year series of productivity data from commercial orange fields was used, based on the georeferencing of fruit storage areas. Global and local filtering strategies were investigated and, subsequently, detailed productivity maps were created using spatialization methods, such as Voronoi polygons and probabilistic interpolation. The methodology of filtering productivity data from the areas contributed by the Voronoi polygons proved to be adequate and allowed obtaining maps that represent information that assist in the planning and management of citrus production. The geostatistical analysis revealed moderate spatial dependence for productivity, justifying the use of probabilistic determinants, but the temporal analysis of the generated maps did not show repeatability in the productive behavior.

KEYWORDS: Geostatistics; Filtering; Voronoi polygon

INTRODUÇÃO

A fruticultura tropical e subtropical no Brasil é amplamente explorada. Frutas cítricas, em especial a laranja, têm destaque no Brasil por ser o maior produtor mundial, com cerca de 17 milhões de

toneladas na safra de 2019 (FAO, 2020). A identificação da variabilidade espaço-temporal da produtividade nos pomares são práticas de agricultura de precisão (AP) fundamentais para o desenvolvimento sustentável da fruticultura e permitem o ajuste das práticas agrícolas (PORTELLA *et al.*, 2016; COLAÇO & MOLIN, 2014). O uso de mapas de produtividade tem se mostrado uma camada de informação importante nesse contexto, pois possibilita a visualização e investigação dos fatores agronômicos associados a essa variabilidade (COLAÇO, 2008; WHITNEY *et al.*, 1999). Embora a colheita na fruticultura ainda seja predominantemente manual, há esforços para adaptar métodos de mapeamento à realidade desses ambientes (MOLIN *et al.*, 2015). Abordagens como o uso de imagens georreferenciadas para predição do número de frutos (ANNAMALAI *et al.*, 2003) e o estudo da variação temporal da temperatura na copa das plantas (BULANON *et al.*, 2008) têm avançado no sentido de facilitar a identificação dos frutos e melhorar a precisão dos mapas de produtividade. Além disso, o processamento de imagens, embora promissor, enfrenta desafios como a detecção inadequada de frutos posicionados no interior da copa (TU *et al.*, 2020). Metodologias como a de georreferenciamento dos sacolões na colheita (MOLIN & MASCARIN, 2007) e a interpretação da zona de contribuição de cada sacolão com o uso do polígono de Voronoi (COLAÇO *et al.*, 2020) são exemplos de abordagens de baixo custo e acessíveis à realidade do produtor brasileiro para expressar variações na produtividade.

OBJETIVOS

Explorar a metodologia proposta por Colaço *et al.*, (2020) para a geração de mapas de produtividade em citros, incorporando processos de filtragem local e técnicas de geoestatística.

MATERIAL E MÉTODOS

O estudo foi desenvolvido em campos comerciais de citros, correspondendo a dez talhões de aproximadamente 25 ha cada, localizados no município de Iaras, SP (22°57'03,5"S; 48°39'37,4"W). Os talhões foram implantados em 2008 e 2009 e são semelhantes em porta enxerto, espaçamento (6,80 m X 2,80 m), todavia para a cultivar copa, os talhões 3, 4, 5, 6, 7, 9 e 10 correspondem a cultivar Valência, enquanto os talhões 1, 2 e 8 são da cultivar Natal, todos não irrigados. Durante as safras de 2012 a 2015, os frutos colhidos foram depositados em sacolões, dispostos a cada três fileiras de laranja e georreferenciados por um receptor Garmin 62S. A capacidade de cada sacolão foi estimada por um líder de colheita para padronizar o volume de laranja nos sacolões e garantir massa constante. O fluxograma da metodologia empregada é esquematizado na Figura 1.

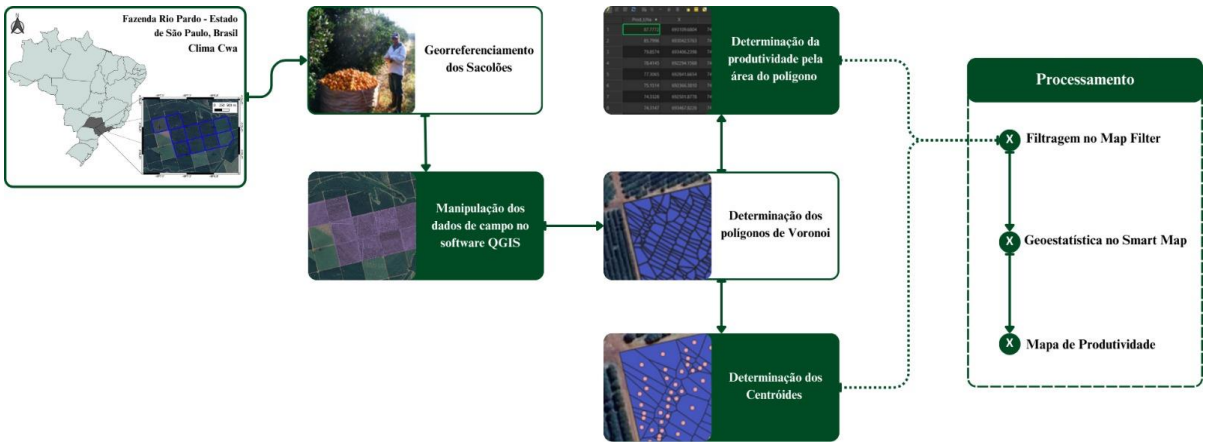


FIGURA 1. Fluxograma de procedimentos para formulação de mapas de produtividade.

Os dados brutos, volume de sacolões, foram submetidos a um processo inicial de limpeza, no qual removeu-se pontos repetidos com sobreposição de coordenadas. Em seguida, no programa QGIS foi

criada uma área de representação para cada sacolão utilizando a ferramenta de polígono de Voronoi, conforme efetuado por Colaço *et al.* (2020). Para obtenção da produtividade, a massa dos sacolões foi considerada uniforme, dividida pela área do polígono de Voronoi e posteriormente associada ao centróide. Devido à exatidão limitada do receptor GNSS (Sistema Global de Navegação por Satélite) ou à proximidade dos sacolões, determinados polígonos gerados representavam áreas pequenas, resultando em produtividades inconsistentes com as observadas em campo. Logo, fez-se necessário estabelecer uma metodologia de filtragem destes dados e, para isto, foi utilizado o programa Mapfilter 2.0, um filtro baseado em distância e estatística (MALDANER *et al.*, 2022). Individualizados por talhão, os dados de produtividade foram filtrados globalmente, baseado na mediana das observações, com variação de limite fixada em 80,00%, e localmente (considerando o comportamento isotrópico e anisotrópico), com dependência espacial de 28,00 m, sendo aproximadamente duas vezes a faixa de colheita. Esse valor foi adotado a partir da interpretação visual do processo de filtragem, fundamentado na eliminação de valores de produção improváveis por extrapolarem a produtividade observada em experimentos com pomares de idade, cultivares copa e porta-enxerto semelhantes (DOMINGUES *et al.*, 2021; PAVÃO, 2016). Após a filtragem, foi realizada a análise geoestatística dos dados a partir do primeiro ajuste dos semivariogramas almejando minimizar a raiz quadrada do erro-médio (RMSE) e maximizar o coeficiente de determinação (R^2). Os mapas de produtividade foram confeccionados por meio do plugin SmartMap (PEREIRA *et al.*, 2023) e utilizando determinadores probabilísticos (krigagem ordinária) caracterizados por considerarem a dependência espacial entre as amostras. Para a análise dos dados, foi realizado a estatística descritiva das produtividades anterior a filtragem global e local (PE) e após a realização do processo (PO), além de compilar os valores associados ao ajuste do semivariograma, tais como o alcance (A), distância máxima entre pontos com dependência espacial, o efeito pepita (Co), porção da variância não explicada pela distância entre pontos, o patamar (Co+c), semivariância máxima do conjunto de dados, assim como a análise do índice de dependência (ID) obtido a partir da divisão do componente estrutural (c) pelo patamar (Co+c). Para interpretação do ID foi utilizado a separação de classes apresentada em CAMBARDELLA *et al.* (1994), em que valores acima de 0,75 indicam alta dependência, valores entre 0,75 e 0,25 indicam dependência moderada, e valores abaixo de 0,25 indicam baixa dependência.

RESULTADOS E DISCUSSÃO

A estatística descritiva dos conjuntos de produção PE e PO são mostrados na Figura 2. Observou-se que o conjunto PE possui maior amplitude de valores e apresentou produtividades improváveis, superando valores observados nos experimentos de Domingues (2021) e Pavão (2016), sendo respectivamente de 48,80 t ha^{-1}e 38,10 t ha^{-1}. Para os anos 2012, 2013, 2014 e 2015, o processo de filtragem removeu 37,96%, 29,90%, 61,87% e 50,59%, respectivamente.

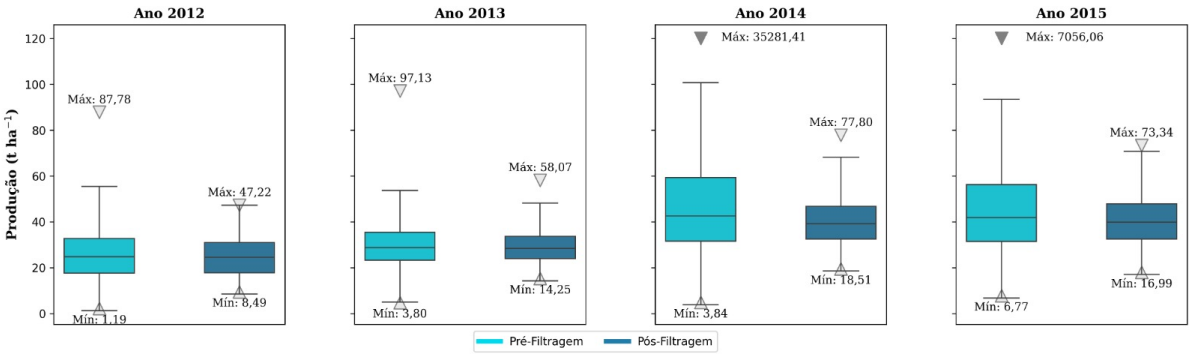


FIGURA 2. Estatística descritiva dos dados de produção PE (pré-filtragem) e PO (pós-filtragem) com descrição dos máximos e mínimos dos conjuntos.

Para análise geoestatística dos dados de produtividade (Tabela 1), foi identificada dependência espacial em todos os anos, ao contrário do observado por Molin e Mascarin (2007) e Molin *et al.* (2011), que obtiveram efeito pepita puro nos ajustes dos semivariogramas. Quanto às métricas de desempenho dos semivariogramas, foram obtidos valores de RMSE de 0,02 a 25,44 para a cultivar Valência, enquanto a cultivar Natal apresentou valores de 1,11 a 31,68, expressando que para os dados utilizados os modelos ajustaram-se melhor para cultivar Valência. Ao analisar o R^2, notou-se valores elevados para ambas as cultivares, o que corrobora com os trabalhos para a cultura do citros realizados por Colaço (2013), em que obteve R^2 variando de 0,81 a 0,99 e dependência espacial de moderada a forte.

TABELA 1: Parâmetros geoestatísticos da produtividade de citros individualizada por cultivar e ano.

Ano	Cultivar	Estatística	Co*	Co+c**	A***	RMSE	R^2	ID****	Análise
2012	Natal	Máximo	5,20	22,46	442,98	5,69	0,99	0,77	Elevado
		Mínimo	2,57	7,32	265,83	1,98	0,96	0,65	Moderado
		Média	3,88	14,89	354,41	3,84	0,98	0,74	Moderado
	Valência	Máximo	10,65	42,94	356,79	10,06	1,00	0,75	Elevado
		Mínimo	1,41	4,39	159,09	0,02	0,99	0,68	Moderado
		Média	6,03	23,67	257,94	5,04	1,00	0,75	Moderado
2013	Natal	Máximo	6,43	13,55	206,23	2,73	0,98	0,53	Moderado
		Mínimo	5,64	13,15	205,11	1,11	0,96	0,57	Moderado
		Média	6,04	13,35	205,67	1,92	0,97	0,55	Moderado
	Valência	Máximo	12,40	50,67	433,44	25,44	0,99	0,76	Elevado
		Mínimo	3,62	14,10	126,97	1,58	0,97	0,74	Moderado
		Média	8,01	32,38	280,21	13,51	0,98	0,75	Elevado
2014	Natal	Máximo	18,63	35,15	120,98	7,49	0,99	0,47	Moderado
		Mínimo	15,53	34,63	120,84	1,65	0,96	0,55	Moderado
		Média	17,08	34,89	120,91	4,57	0,98	0,51	Moderado
	Valência	Máximo	22,05	65,83	270,31	12,08	1,00	0,67	Moderado
		Mínimo	21,78	63,51	144,99	5,00	1,00	0,66	Moderado
		Média	21,91	64,67	207,65	8,54	1,00	0,66	Moderado
2015	Natal	Máximo	27,51	78,84	188,34	31,68	1,00	0,65	Moderado
		Mínimo	7,18	16,59	104,48	1,16	0,97	0,57	Moderado
		Média	17,34	47,72	146,41	16,42	0,98	0,64	Moderado

	Máximo	26,40	48,31	143,83	3,95	0,99	0,45	Moderado
Valência	Mínimo	15,58	26,27	143,55	1,55	0,98	0,41	Moderado
	Média	20,99	37,29	143,69	2,75	0,99	0,44	Moderado

* Efeito pepita; ** Patamar; *** Alcance; **** Índice de dependência espacial.

A partir dos mapas gerados (Figura 3), observa-se a variabilidade da produtividade intra e entre talhões no espaço e no tempo em decorrências das variedades, desenvolvimento de planta, sanidade ou características de solo. Analisando-se temporalmente, não foi observado repetibilidade no comportamento produtivo. Verificou-se aumento da produtividade média ao longo dos anos, pois o período analisado contemplou a idade do pomar do terceiro ao quinto ano, período de crescimento. Foi possível identificar que os talhões 9 e 10 apresentam menor produtividade em decorrência de serem pomares implantados mais tardiamente. A representação visual obtida após o processo de filtragem permite caracterizar a variabilidade espacial sem a possível interferência de valores de produtividade que não condizem à realidade no campo e que prejudicam a interpretação da informação pelo gestor do pomar. É possível considerar futuros trabalhos referente à análise geoestatística de diferentes estratégias filtragens, assim como a exploração da dependência espacial nesse processo, e comparar com mapas de produtividades obtidos com a mesma base de dados sem a etapa de filtragem.

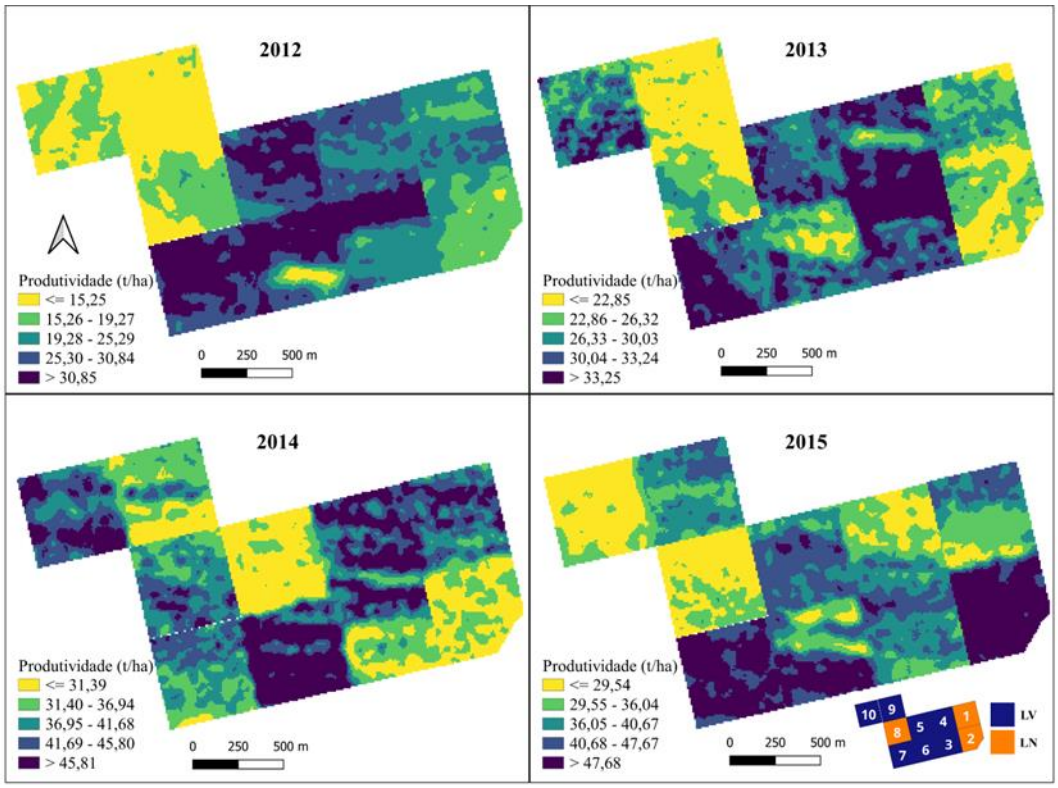


FIGURA 3. Superfície interpolada por krigagem ordinária correspondente a produtividade da laranja do ano de 2012 até 2015 em que LV representa a cultivar Laranja Valência e LN cultivar Laranja Natal.

CONCLUSÃO

A geração de mapas de produtividade em citros possui potencial de aprimoramento. O incremento da filtragem local, usando o programa Mapfilter 2.0 com limite de variação de 80,00% e dependência espacial de 28,00 m, e de técnicas geoestatística permitiu a eliminação de dados de produtividade

inconsistentes e garantiu maior similaridade com as referências literárias e observações de campo. Portanto, a abordagem aplicada para a elaboração de mapas de produtividade em citros é uma forma de explorar uma metodologia já existente e incrementar métricas de filtragem que podem contribuir para a gestão de pomares.

REFERÊNCIAS

ANNAMALAI, P.; LEE, W. S. **Citrus Yield Mapping System Using Machine Vision**. 2003

BULANON, D. M.; BURKS, T. F.; ALCHANATIS, V. Study on temporal variation in citrus canopy using thermal imaging for citrus fruit detection. **Biosystems Engineering**, v. 101, n. 2, p. 161-171, 2008.

CAMBARDELLA, C.A.; MOORMAN, T.B.; NOVAK, J.M.; PARKIN, T.B.; KARLEN, D.L.; TURCO, R.F. & KONOPKA, A.E. Field-scale variability of soil properties in Central Iowa soils. **Soil Science Society Of America Journal**, 58:1501-1511, 1994.

COLAÇO, A. F. **Efeito da adubação em doses variadas em pomares de laranjeiras ao longo de quatro safras**. 2013. Dissertação (Mestrado em Engenharia de Sistemas Agrícolas) - Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 2013. doi:10.11606/D.11.2013.tde-21022013-160125.

COLAÇO, A. F.; MOLIN, J. P.; EHSANI, R. **Agricultura de Precisão e Colheita Mecanizada em Citros**. Esalq, Piracicaba- SP Dezembro, 2008.

COLAÇO, A. F.; MOLIN, José P. **Agricultura de Precisão em Citros Mapeamento de Produtividade e Adubação em Taxas Variáveis**. Agricultura de Precisão, Piracicaba, v. 1, n. 1, p. 1-1, out. 2014.

COLAÇO, A. F.; TREVISAN, R. G.; KARP, F. H. S.; MOLIN, J. P. Yield mapping methods for manually harvested crops. **Computers and Electronics in Agriculture**, v. 177, p. 105693, 2020.

DOMINGUES, A. R.; MARCOLINI, C. D. M.; GONÇALVES, C. H. da S.; GONÇALVES, L. S. A.; ROBERTO, S. R.; CARLOS, E. F. Fruit Ripening Development of 'Valencia' Orange Trees Grafted on Different 'Trifoliata' Hybrid Rootstocks. **Horticulturae**, Vol. 7, Page 3, v. 7, n. 1, p. 3, 2021

FOOD AND AGRICULTURE ORGANIZATIONS OF THE UNITED NATIONS. **Citrus Fruit Statistical Compendium**. Rome, 2020,

MALDANER, L. F., MOLIN, J. P., & SPEKKEN, M. Methodology to filter out outliers in high spatial density data to improve maps reliability. **Scientia Agricola**, *79*(1), 2022.

MENDES, L. G. **Efeitos da adubação em doses variadas em pomares de laranja**. 2018. Dissertação (Mestrado em Engenharia de Sistemas Agrícolas) - Escola Superior de Agricultura Luiz de Queiroz, Université de São Paulo, Piracicaba, 2018. doi:10.11606/D.11.2019.tde-22032019-180011.

MOLIN, J P.; MASCARIN, L. S. Colheita de citros e obtenção de dados para mapeamento da produtividade. **Engenharia Agrícola**, v. 27, pág. 259-266, 2007.

MOLIN, J. P.;AMARAL, L. R.;COLAÇO, A. F. **Agricultura de Precisão**. São Paulo:Oficina de Textos, 2015.

MOLIN, J. P.; COLOAÇO, A. F.; CARLOS, E. E. Orange yield and plant gap mapping caused by disease. In: EUROPIAN CONFERENCE ON PRECISION AGRICULTURE, 2011. Praga. **Anais.** Praga: ISPA, 2011.

PAVÃO, G.C. **Produtividade e qualidade de frutos de laranjeira valência fertirrigadas sob déficit hídrico controlado na região centro-sul do estado de São Paulo**. 2016. Dissertação (em Agricultura Tropical e Subtropical) - Instituto Agronômico, Campinas, 2016.

PEREIRA, G. W; VALENTE, D. S. M; QUEIROZ, D.M; COELHO, A. L. F. SMART-MAP: Plugin QGIS para interpolação utilizando Krigagem Ordinária e Machine Learning. *In*: CONGRESSO BRASILEIRO DE AGROINFORMÁTICA (SBIAGRO), 14. , 2023, Natal/RN. **Anais** [...]. Porto Alegre: Sociedade Brasileira de Computação, 2023

PORTELLA, C. R.; MARINHO, C. S.; AMARAL, B. D.; CARVALHO, W. S. G.; CAMPOS, G. S.; SILVA, M. P. S. da; SOUSA, M. C. de. Desempenho de cultivares de citros enxertadas sobre o trifoliateiro "Flying Dragon" e limoeiro "Cravo" em fase de formação do pomar. **Bragantia**, v. 75, n. 1, p. 70-75, jan. 2016.

TU, S.; PANG, J.; LIU, H.; ZHUANG, N.; CHEN, Y.; ZHENG, C.; WAN, H.; XUE, Y. Passion fruit detection and counting based on multiple scale faster R-CNN using RGB-D images. **Precision Agriculture**, v. 21, n. 5, p. 1072-1091, 2020.

WHITNEY, L.D.; MILLER, W.M.; WHEATON, T.A.; SALYANI, M.; SCHUELLER, J.K. Precision farming applications in Florida citrus. **Applied Engineering in Agriculture**, St Joseph, v. 15, n. 5, p. 399-403, 1999.

7. Outros

EXPLORANDO A RELAÇÃO ENTRE MEDIDAS MORFOLÓGICAS E MASSA CORPORAL EM BOVINOS DE LEITE: UMA ANÁLISE POR ÁRVORE DE DECISÃO

Franck Morais de Oliveira [1]; Patricia Ferreira Ponciano Ferraz [2]; Gabriel Araujo e Silva Ferraz [3]; Jacqueline Cardoso Ferreira [4]; Ana Luiza Guimaraes Andre [5]

[1]Doutorando. Universidade Federal de Lavras, Departamento de Engenharia Agrícola. Campus Universitário . 37200000 - Lavras, MG - Brasil. Universidade Federal de Lavras - UFLA; [2]Docente. Universidade Federal de Lavras, Departamento de Engenharia Agrícola. Campus Universitário . 37200000 - Lavras, MG - Brasil. Universidade Federal de Lavras - UFLA; [3]Docente. Universidade Federal de Lavras, Departamento de Engenharia Agrícola. Campus Universitário . 37200000 - Lavras, MG - Brasil. Universidade Federal de Lavras - UFLA; [4]Pesquisadora. Universidade Federal de Lavras, Departamento de Engenharia Agrícola. Campus Universitário . 37200000 - Lavras, MG - Brasil. Universidade Federal de Lavras - UFLA; [5]Graduanda. Universidade Federal de Lavras, Departamento de Zootecnia. Campus Universitário . 37200000 - Lavras, MG - Brasil. Universidade Federal de Lavras - UFLA

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A avaliação das medidas físicas dos bovinos de leite é essencial na pecuária, impactando a seleção e o manejo produtivo. A relação entre medidas morfológicas e a massa corporal (MC) é muito importante, pois permite o uso de algoritmos de aprendizado de máquina para otimizar a gestão de alimentação e seleção de animais. O objetivo deste trabalho é utilizar uma árvore de decisão para classificar algumas medidas morfológicas em grupos de MC. No estudo, foram utilizados dados de 103 vacas leiteiras da raça Holandesa de uma fazenda da cidade de Ijaci-MG, coletados durante a pesagem em uma balança eletrônica após a primeira ordenha do dia às 05:00h. Medidas como largura torácica, largura corporal e largura da garupa deram uma boa correlação positiva com a MC de 0,90%, 0,90% e 0,89% respectivamente e foram utilizadas como variáveis preditoras da MC. O conjunto de dados foi dividido em 80% para conjunto de treinamento e 20% para o conjunto de teste para desenvolver e validar o modelo do algoritmo. Todo o desenvolvimento estatístico e criação da árvore foi realizado no Software RStudio. O modelo da árvore de decisão apresentou uma acurácia de 94,74% e uma precisão de 95,74%. Essas análises sugerem que a árvore de decisão é um instrumento eficaz para a avaliação da MC com base em medidas físicas, proporcionando uma abordagem precisa e eficiente na pecuária.

PALAVRAS-CHAVE: Vaca leiteira; aprendizado de máquina; modelo de classificação

ABSTRACT

The evaluation of the physical measurements of dairy cattle is essential in livestock farming, impacting selection and production management. The relationship between morphological measurements and body mass is very important, as it allows the use of machine learning algorithms to optimize feeding management and animal selection. The objective of this work is to use a decision tree to classify some morphological measurements into body mass groups. In the study, data from 103 Holstein dairy cows from a farm in the city of Ijaci-MG were used, collected during weighing on an electronic scale after the first milking of the day at 5:00 am. Measurements such as chest width, body width and rump width gave a good positive correlation with body mass of 0.90%, 0.90% and 0.89% respectively and were used as predictor variables of body mass. The dataset was divided into 80% training set and 20% testing set to develop and validate the algorithm model. All statistical development and tree creation was carried out using RStudio Software. The decision tree model showed an accuracy of 94.74% and a precision of 95.74%. These analyzes suggest that the decision tree is an effective tool for assessing body mass based on physical measurements, providing an accurate and efficient approach in livestock farming.

KEYWORDS: Dairy cow; machine learning; classification model

INTRODUÇÃO

Os bovinos de leite desempenham um papel crucial na produção de laticínios e na economia agrícola, sendo essencial compreender e estimar suas dimensões corporais para melhorar a produtividade e o bem-estar desses animais. As medidas corporais podem ser utilizadas para estimar a condição corporal e a massa corporal (MC) dos animais, e classificar os melhores fenótipos para animais mais saudáveis, produtivos e duradouros (MARTINS et. al., 2020). Um método que é o mais aceito para determinação da MC do animal é uma balança calibrada, porém, nem sempre se tem uma disponível na fazenda, e por isso métodos alternativos para se estimar a MC são necessários (HEINRICHS et. al., 2017). Essa real necessidade de uma base para estimar a MC de bovinos leiteiros de uma maneira mais fácil e com um mínimo de custo e tempo já foi apresentada em (DAVIS, 1961), e em suas investigações tentou-se fornecer tal base, determinando as relações entre várias dimensões e a MC dos animais, chegando à conclusão de que o perímetro do coração era a medida mais correlacionada com sua MC.

Em uma propriedade leiteira, muitas decisões são baseadas em MC do animal, como para a formulação da dieta, essa massa e altura adequados para novilhas e o manejo sanitário (HEINRICHS et. al., 2017; MARTINS et. al., 2020). No entanto, realizar essas medições morfológicas em bovinos representa um desafio significativo devido à necessidade de treinamento especializado, à natureza trabalhosa do processo e à possibilidade de variações nas medições, e neste contexto, algoritmos de inteligência artificial e aprendizado de máquina surgiram na pecuária de precisão como uma solução mais precisa e confiável para superar esses obstáculos.

Uma árvore de decisão é uma estrutura de árvore semelhante a um fluxograma. O nó interno denota um teste em um atributo, cada ramificação representa um resultado do teste, e os nós folha representam classes ou distribuição de classe (QUINLAN, 1986). O primeiro nó que aparece na árvore, o nó mais alto, é chamado de nó raiz e existem também os nós que se localizam no interior da árvore conhecidos como nós internos e por fim, os últimos são os que representam as classes ou rótulos atribuídos às instâncias de dados após percorrer toda a árvore de decisão a partir do nó folha, são conhecidos como nós terminais ou nós folhas (QUINLAN, 1986; GUPTA, 2012).

OBJETIVOS

Em vista disto, este trabalho tem o objetivo de testar a hipótese de que por meio da análise de medidas morfológicas de um bovino de leite, é possível identificar as variáveis mais significativas que se correlacionam com a massa corporal (MC) e construir uma árvore de decisão capaz de predizer com precisão a MC dos animais com base nessas características.

MATERIAL E MÉTODOS

O estudo foi conduzido em uma fazenda de bovinos leiteiros na cidade de Ijaci-MG (21°09'40.1"S 44°55'45.3"W). Foram coletados dados de 103 vacas em lactação, que estavam alojadas em um galpão do tipo free-stall, durante o mês de janeiro de 2024. A coleta ocorreu imediatamente após a saída da ordenha, que começava às 05:00 da manhã, e as medições foram concluídas por volta das 8:30 da manhã. Foram utilizadas 2 fitas métricas, sendo uma fixada em um instrumento hipômetro construído de canos pvc para aumentar a precisão das medições lineares no dorso de cada animal e na parte lateral das vacas, e outra fita utilizada para medições de perímetros. A balança eletrônica utilizada foi uma digital TRU-TEST EziWeigh 5.

Neste estudo, foram coletadas medidas de oito variáveis dos bovinos de leite registradas e apresentadas na Figura 1 e a MC. A massa do animal foi obtida em quilogramas, observando que a variação de massa encontrada foi de 450kg a 820kg e todas as outras medidas coletadas em centímetros. Para coleta das medidas foram adotadas metodologias utilizadas em (ADINATA et. al. 2017; MARTINS et. al., 2020; TYASI, 2023; WARMAN et. al., 2023), onde suas medidas incluíram dimensões físicas do dorso, como largura do tórax, largura do abdome, comprimento dorsal e uma medida de largura na garupa realizada segundo a medição feita por Cerqueira et. al. (2013), chamada de largura biilíaca ou largura entre ísquios; dimensões laterais, como altura e profundidade corporal. Além dessas medidas foram coletadas o perímetro torácico, que é uma medida feita por toda a circunferência do animal localizada atrás das patas dianteiras, e perímetro corporal, medida pela maior circunferência no peitoral do animal, além da pesagem da vaca. Portanto, o conjunto de dados foi composto por 103 amostras e 9 variáveis.

O software RStudio (ALLAIRE, 2012; R CORE TEAM, 2013) foi utilizado para análises de correlação inicial, identificando as melhores correlações entre as variáveis. Em seguida, foi empregado o algoritmo K-means para clusterizar os dados de MC em três classes distintas, com o objetivo de segmentar esses dados. Por fim, o RStudio também foi utilizado para criar a árvore de decisão com base nessas classes e nas variáveis relevantes.

RESULTADOS E DISCUSSÃO

Primeiramente, uma análise de correlação entre as variáveis foi realizada e pode ser observada na Figura 1.

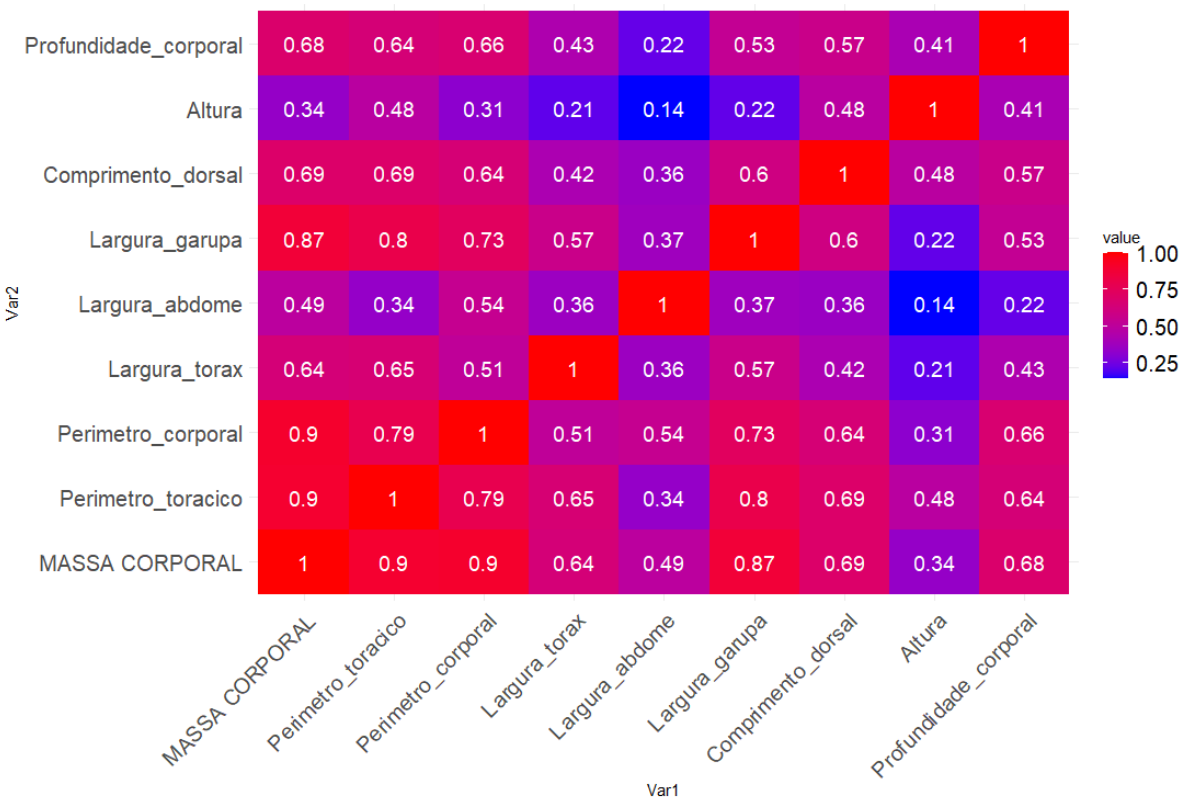


Figura 1. Gráfico de correlação entre as variáveis medidas.

Ao realizar a análise da matriz de correlação entre as variáveis medidas e a MC dos bovinos, observa-se que algumas variáveis apresentaram correlações significativas com a massa. Especificamente, foram identificadas fortes correlações positivas com o perímetro torácico (0,90), o perímetro corporal (0,90) e a medida de largura na garupa (0,87). Esses valores indicam uma associação robusta entre essas medidas morfológicas e a MC dos animais. Por outro lado, as demais variáveis demonstraram

correlações interessantes, porém inferiores a 0,70, sugerindo uma relação mais fraca com a MC. Com base nesses resultados, optou-se por selecionar as três variáveis com as correlações mais elevadas - perímetro torácico, perímetro corporal e largura da garupa - como preditores principais para a análise de classificação. Em Pereira et. al. (2021) foi utilizado uma equação de regressão linear simples que envolve o perímetro torácico com um $r^2 = 0,89$, $P < 0,01$, o que mostra que algumas partes do animal já indicam boas correlações com sua MC.

Para estimar a MC dos bovinos com base nas variáveis preditoras, foi utilizado uma árvore de decisão. A árvore de decisão oferece uma abordagem interpretável e intuitiva para modelar a relação entre essas variáveis e a MC dos animais. Esta técnica de predição já tem sido constantemente utilizada em vários estudos com bons resultados em várias áreas, como por exemplo: predição da frequência respiratória de leitões submetidos ao frio (FERRAZ et. al., 2021); predição de produção de leite de lactação em vacas polonesas da raça Holandesa-Frísia com base em dados registrados pelo sistema de ordenha automática durante o período Peri parturiente (KLI? et. al., 2021); predição de risco de mastite clínica em vacas leiteiras em lactação (LUO, 2023). A escolha desta técnica para este trabalho se justifica pela sua capacidade de fornecer ideias claras sobre quais variáveis são mais relevantes para a estimativa da MC dos bovinos, facilitando a interpretação dos resultados e a tomada de decisões baseadas em dados, além de sua fácil implementação e interpretação. Ao construir a árvore de decisão, pretende-se identificar padrões nos dados que permitam classificar os bovinos em diferentes faixas de MC com base em suas características morfológicas.

Antes de aplicar a árvore de decisão, o primeiro passo consistiu em utilizar o algoritmo K-means para classificar os dados de MC em três classes distintas: leve, média e pesada. O algoritmo classificou o primeiro cluster como bovinos de MC leve (450 kg a 535 kg), o segundo cluster como bovinos de MC média (540 kg a 650 kg) e o terceiro cluster como bovinos de maiores massas corporais (670 kg a 820 kg) (Figura 2).

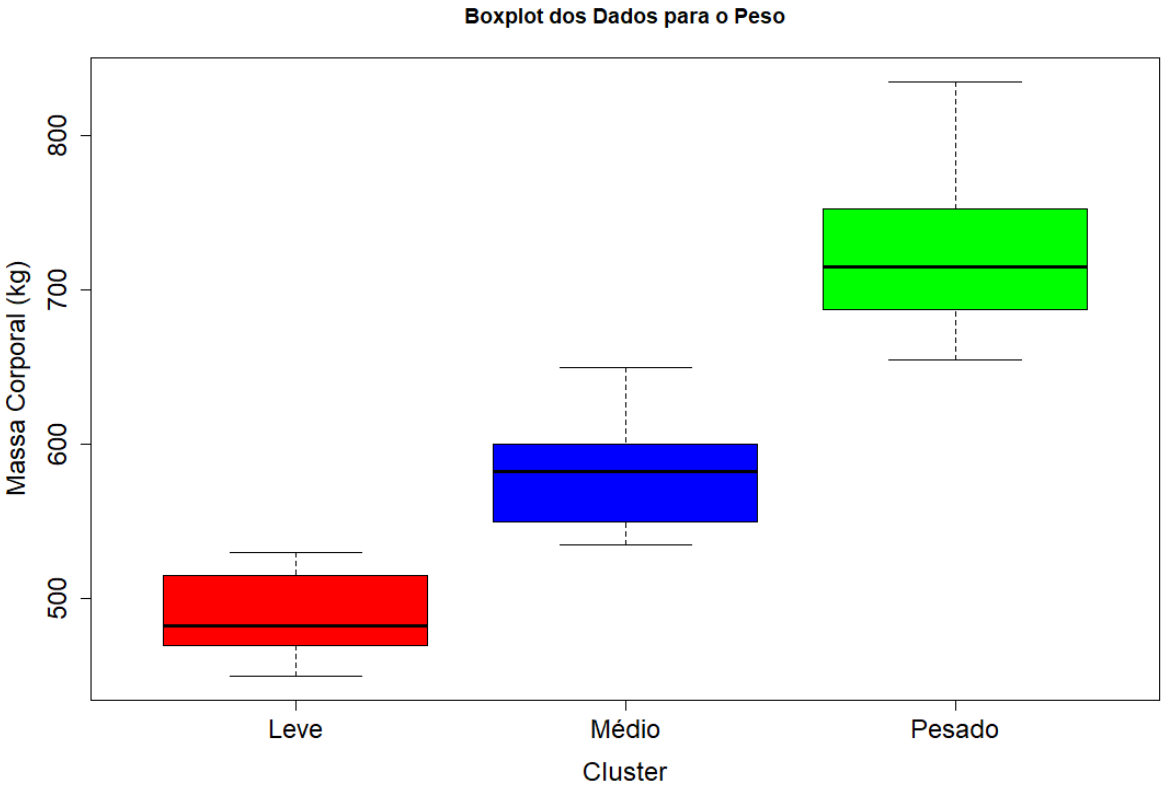


Figura 2. Clusters criados pelo algoritmo K-means.

Em seguida a árvore de decisão (Figura 3) foi construída para modelar a relação entre as variáveis preditoras selecionadas e a MC dos animais. Ela oferece uma visão sobre as decisões tomadas com base nos critérios específicos definidos. Foi adotada uma divisão de 80% dos dados para treino e 20% dos dados para teste da árvore.

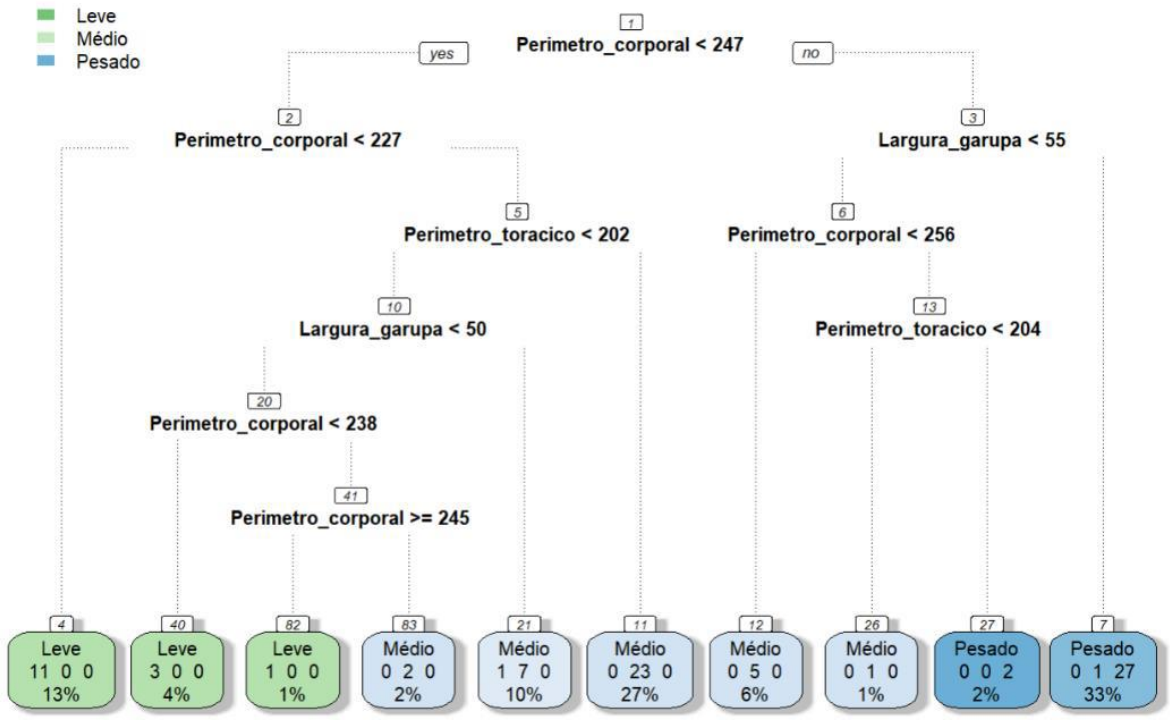


Figura 3. Árvore de decisão para classificação de MC.

O modelo da árvore de decisão apresentou uma acurácia de 94,74% e uma precisão de 95,23% sobre os dados de teste. Esses resultados indicam que o modelo de árvore de decisão foi capaz de fazer previsões precisas em relação às classes das observações de teste. A alta acurácia de 94,74% indica que a maioria das classificações feitas pelo modelo foi correta em relação às classes verdadeiras dos dados de teste. Além disso, a precisão de 95,23% mostra a proporção de previsões positivas (verdadeiros positivos) que realmente foram corretas, em relação a todas as previsões positivas feitas pelo modelo. Essas métricas sugerem que o modelo de árvore de decisão é eficaz na classificação das observações em relação à variável de interesse.

CONCLUSÃO

Durante o período do experimento, observou-se que a massa corporal dos bovinos leiteiros variou entre 450kg e 820kg. Empregando o modelo de árvore de decisão proposto, foi possível classificar com sucesso as massas desses animais, utilizando como base as variáveis corporais medidas fisicamente. Variáveis como perímetro torácico, perímetro corporal e largura da garupa mostraram-se correlacionadas com a massa corporal, permitindo uma classificação eficaz. Esse resultado enfatiza a eficiência das árvores de decisão como ferramenta para a predição de massa corporal em bovinos leiteiros, utilizando medidas corporais específicas. Tal abordagem oferece uma metodologia precisa e confiável para a gestão pecuária, possibilitando uma melhor tomada de decisão no manejo dos animais, visando otimizar tanto a saúde quanto a produtividade do rebanho.

AGRADECIMENTOS

Os autores agradecem a Fapemig (Projeto APQ-01082-21 e BPD-00034-22), a CNPq (Projeto 404420/2021-4), a CAPES e ao Programa de Pós-Graduação em Engenharia Agrícola da UFLA.

REFERÊNCIAS

ADINATA, Y., PAMUNGKAS, D., LUTHFI, M., RASYID, A., & KRISHNA, N. H. (2017, March). Phenotypic Characterization of Jawa Brebes (Jabres) Cattle. In International Seminar on Livestock Production and Veterinary Technology (pp. 24-29).

ALLAIRE, J. (2012). RStudio: integrated development environment for R. Boston, MA, 770(394), 165-171.

CERQUEIRA, J. O. L., ARAÚJO, J. P. P., VAZ, P. S., CANTALAPIEDRA, J., BLANCO-PENEDO, I., & NIZA-RIBEIRO, J. J. R. (2013). Relationship between Zoometric Measurements in HolsteinFriesian Cow and Cubicle Size in Dairy Farms. International Journal of Morphology.

DAVIS, H. P., SWETT, W. W., & HARVEY, W. R. (1961). Relation of heart girth to weight in Holsteins and Jerseys.

FERRAZ, P. F. P., CADAVID, V. G., FERRAZ, G. A. S., SARAZ, J. A. O., ROSSI, G., & BARBARI, M. (2021). Decision three to predict respiratory rate of piglets submitted to cold conditions.

HEINRICHS, A. J., HEINRICHS, B. S., JONES, C. M., ERICKSON, P. S., KALSCHEUR, K. F., NENNICH, T. D., HEINS, B.J. & CARDOSO, F. C. (2017). Verifying Holstein heifer heart girth to body weight prediction equations. Journal of dairy science, 100(10), 8451-8454.

KLI?, P., PIWCZY?SKI, D., SAWA, A., & SITKOWSKA, B. (2021). Prediction of lactational milk yield of cows based on data recorded by AMS during the periparturient period. Animals, 11(2), 383.

LUO, W., DONG, Q., & FENG, Y. (2023). Risk prediction model of clinical mastitis in lactating dairy cows based on machine learning algorithms. Preventive Veterinary Medicine, 221, 106059.

MARTINS, B. M., MENDES, A. L. C., SILVA, L. F., MOREIRA, T. R., COSTA, J. H. C., ROTTA, P. P., CHIZZOTTI, M.I. & MARCONDES, M. I. (2020). Estimating body weight, body condition score, and type traits in dairy cows using three dimensional cameras and manual body measurements. Livestock science, 236, 104054.

PEREIRA, M. N., JÚNIOR, N. M., OLIVEIRA, R. C., SALVATI, G. G. S., & PEREIRA, R. A. N. (2021). Methionine precursor effects on lactation performance of dairy cows fed raw or heated soybeans. Journal of Dairy Science, 104(3), 2996-3007.

QUINLAN, J. R. (1986). Induction of decision trees. Machine learning, 1, 81-106.

WARMAN, A. T., FADHILAH, G. T., IBRAHIM, A., ATMOKO, B. A., BALIARTI, E., & PANJONO, P. (2023). Morphometric characterization and zoometric indices of female Bali cattle reared in Lombok Tengah District, West Nusa Tenggara, Indonesia. Biodiversitas Journal of Biological Diversity, 24(2).

R CORE TEAM, R. (2013). R: A language and environment for statistical computing.

TYASI, T. L., & BAYU PUTRA, W. P. (2023). Principal Component Analysis (PCA) in the body measurements of Nguni cows.

ADOÇÃO DE FERRAMENTAS DE FRUTICULTURA DE PRECISÃO NA VITIVINICULTURA DO RIO GRANDE DO SUL

Teresa Enderle [1]; Júlia Faccin Faé [1]; Luís Felipe Rosseto Gerlach [1]; Gilmar Arduino Bettio Marodin [2]; André Luis Vian [2]

[1]Discente. Faculdade de Agronomia, Campus do Vale - Av. Bento Gonçalves, 7712 - Agronomia, Porto Alegre - RS, 91540-000. Universidade Federal do Rio Grande do Sul; [2]Docente. Faculdade de Agronomia, Campus do Vale - Av. Bento Gonçalves, 7712 - Agronomia, Porto Alegre - RS, 91540-000. Universidade Federal do Rio Grande do Sul

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A implementação das técnicas de Agricultura de Precisão na viticultura, é denominada de Viticultura de Precisão (VP), e consideramos uma abordagem recente no país. O objetivo deste estudo foi avaliar a atual adoção das ferramentas e técnicas da VP no Rio Grande do Sul, buscando entender o perfil dos produtores que adotam essas ferramentas, e quais os fatores que influenciam na decisão do seu uso. A coleta de dados envolveu a elaboração de um questionário online para viticultores e posterior análise descritiva. Foram identificados que 64% dos viticultores adotam alguma ferramenta de VP. A principal ferramenta de VP adotada são softwares de gestão da propriedade, seguido por aplicativos de monitoramento e taxa variada de fertilizantes e defensivos. As principais dificuldades que limitam a adoção de VP são: custo inicial para a implementação das ferramentas, seguido por interpretação e aplicação dos resultados. Destaca-se que 56% dos entrevistados têm a intenção de iniciar o uso de tecnologias nos próximos dois anos. Esse cenário demonstra uma tecnologia ainda em adoção inicial pela maioria dos agricultores, mas com grande possibilidade de expansão.

PALAVRAS-CHAVE: *Vitis vinifera*; adoção de tecnologias; difusão de inovação

ABSTRACT

The implementation of Precision Agriculture techniques in viticulture is referred to as Precision Viticulture (PV), and it is considered a recent approach in the country. The aim of this study was to evaluate the current adoption of PV tools and techniques in Rio Grande do Sul, seeking to understand the profile of producers who adopt these tools and the factors influencing their decision to use them. Data collection involved the creation of an online questionnaire for grape growers and subsequent descriptive analysis. It was identified that 64% of grape growers adopt some PV tool. The main PV tools adopted are farm management software, followed by monitoring applications and variable rate fertilizers and pesticides. The main difficulties limiting the adoption of PV are the initial cost of implementing the tools, followed by the interpretation and application of results. It is noteworthy that 56% of respondents intend to start using technologies in the next two years. This scenario demonstrates a technology still in the initial adoption phase by most farmers but with great potential for expansion.

KEYWORDS: ;

INTRODUÇÃO

Atualmente a Agricultura de Precisão (AP) desempenha um papel importante no setor agrícola, auxiliando produtores a tomar decisões mais precisas e sustentáveis no manejo dos recursos agrícolas (BOLFE et al., 2020). Nesse cenário, a Viticultura de Precisão (VP) surge como uma técnica moderna e eficaz de avaliação da variabilidade espacial do solo e de plantas, por meio do emprego de

ferramentas tecnológicas que são utilizadas na AP, tendo como objetivo o monitoramento e gestão da variabilidade espacial de todas as variáveis físicas, químicas e biológicas que estão interligadas com a produtividade e qualidade de um vinhedo. O setor vitivinícola brasileiro apresenta concentração predominante no estado do Rio Grande do Sul (RS), que abrange cerca de 63% da área vitícola nacional e assume a posição de principal produtor de uvas, englobando variedades viníferas e de mesa. Também é responsável por 90% da produção de vinhos e sucos, bem como aproximadamente 85% da produção de espumantes em 2018. Nos últimos anos, a indústria vitivinícola no RS passou por transformações, uma vez que enfrenta uma considerável concorrência de produtos importados, especialmente no segmento de vinhos finos. Nesse contexto, observa-se um esforço notável por parte de instituições ligadas ao setor, bem como de algumas empresas líderes, no sentido de elevar a qualidade dos vinhos, por meio da incorporação de tecnologias vitícolas e enológicas modernas (PEREIRA et al., 2020). As técnicas da VP podem contribuir para a produção de vinhos de maior qualidade, ao mesmo tempo em que reduz os custos operacionais e melhora o desempenho nas colheitas, buscando alcançar o potencial máximo dos vinhedos no que diz respeito à qualidade enológica.

OBJETIVOS

O objetivo deste estudo foi avaliar a taxa de uso da VP e compreender o perfil dos usuários, e quais os fatores que influenciam na decisão de utilizar ou não essa tecnologia pelos vitivinicultores do RS.

MATERIAL E MÉTODOS

O trabalho foi realizado com base em uma pesquisa online que se baseou na metodologia proposta por Anselmi (2012), que se caracteriza como um estudo de caráter exploratório e descritivo, através do uso de técnicas de análises qualitativas e quantitativas. Para essa etapa do trabalho, desenvolveu-se um questionário, utilizado como técnica de investigação, composto por um conjunto de questões abertas, fechadas e em escala de Likert de cinco pontos. A primeira parte da pesquisa foi composta por questões com a finalidade de caracterizar o perfil socioeconômico do entrevistado (cidade, idade, gênero, grau de instrução, profissão). A segunda parte contemplou informações sobre a relação com a adoção da VP (área, destino da produção, sistema de condução, conhecimentos sobre agricultura de precisão e adoção). Por fim, a terceira e quarta etapa da pesquisa compreenderam questões a respeito da percepção das ferramentas na VP (tempo de uso, tecnologia utilizada, grau de satisfação, expectativa de uso, desafios no emprego das ferramentas, fontes de informação). Destacamos que serão apresentados os dados relativos a segunda e terceira etapa do questionamento. O questionário foi aplicado no formato online, entre maio de 2022 e agosto de 2023, através da plataforma Google Forms®. Foi divulgado através de e-mails e contato direto, com vitivinicultores, vinícolas e instituições do setor para direcionamento ao público-alvo. A partir das respostas obtidas selecionou-se 85 questionários preenchidos de forma exclusiva por vitivinicultores. As respostas foram submetidas à tabulação de dados e posterior análise estatística descritiva através do programa Microsoft Excel®, a fim de traçar um perfil do produtor e compreender o estado da adoção de ferramentas de AP na vitivinicultura no estado do RS.

RESULTADOS E DISCUSSÃO

A maioria dos entrevistados estão localizados na região da Serra Gaúcha, maior região produtora do RS e do Brasil, com 76%, distribuídos entre os municípios de Monte Belo do Sul, Bento Gonçalves, Garibaldi, Farroupilha, Cotiporã, Pinto Bandeira e Piratini. As regiões produtoras emergentes, como Campanha, Serra do Sudeste e Campos de Cima da Serra, juntas totalizaram apenas 5%, sendo representada pelas cidades de Santana do Livramento, Itaqui, Dom Feliciano, Encruzilhada do Sul e Vacaria. O restante dos respondentes pertencia a regiões que não são consideradas polos vitícolas do estado, como a região Metropolitana e Vale do Taquari, nas cidades de Porto Alegre, Viamão e

Lajeado. Com base nas respostas obtidas, verificou-se que 81% dos vitivinicultores já ouviram falar da VP, enquanto apenas 19% não conhecem ou ouviram falar sobre VP (Figura 1).

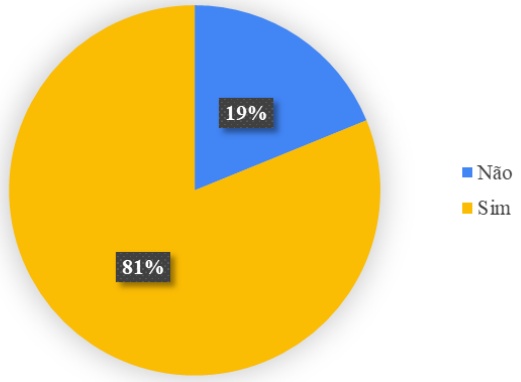


FIGURA 1 - Percentual (%) de vitivinicultores que conhecem e não conhecem VP.

Os vitivinicultores que utilizam ferramentas de VP, verificou-se que a categoria: Software de gestão da propriedade é atualmente a ferramenta mais utilizada com 63% das respostas, seguido pelos aplicativos de monitoramento (43%) e de taxa variada de fertilizantes e defensivos agrícolas (36%) (Figura 2). Destaca-se que 30% das respostas realizam mapeamento de colheita, dado importante para mapeamento da produção e qualidade das uvas, tanto das propriedades como das regiões vitícolas.

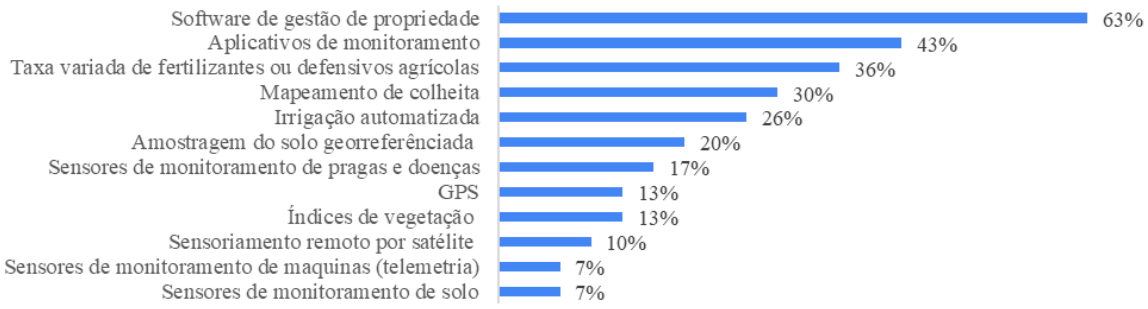


FIGURA 2 - Ferramentas de AP que os produtores fazem uso nas propriedades.

Shang et al. (2021), pesquisando sobre a difusão de ferramentas tecnológicas concluiu que o processo de difusão de tecnologias baseia-se em cinco estágios no processo de decisão sobre adoção da inovação: conhecimento, persuasão, decisão, implementação e confirmação. Dessa forma, seguindo o primeiro estágio de difusão da tecnologia, quando questionados sobre sua percepção dos principais benefícios da VP, os viticultores destacaram que a redução de custos e a melhoria da qualidade da uva e do vinho são os benefícios mais importantes (ambos com 57%) (Figura 3).

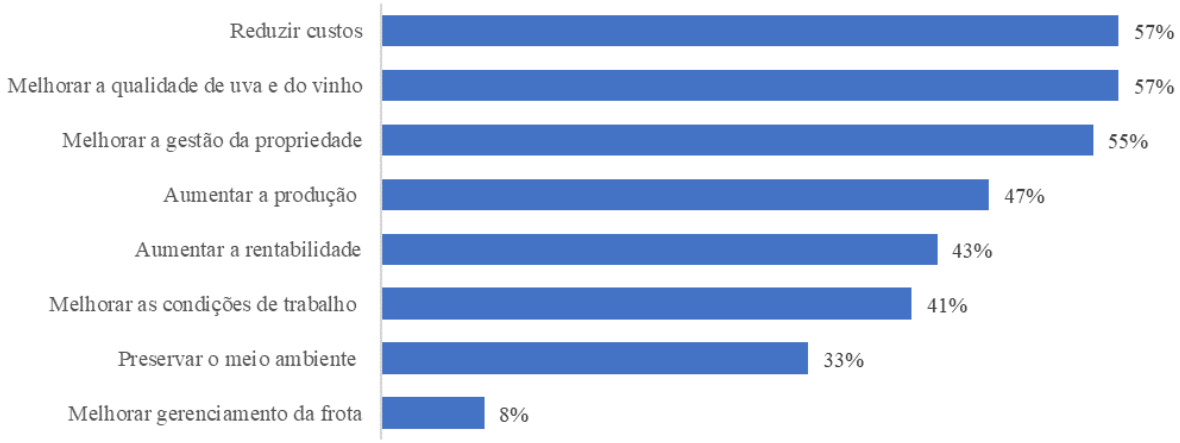


FIGURA 3 - Principais benefícios da VP na percepção dos viticultores.

O comportamento de adoção da VP pode ser determinado pelas características da cultura em que o produtor está inserido e da sua própria personalidade, mas também é influenciado pelas condições estruturais, políticas e econômicas do sistema agrícola. Nesse âmbito, segundo estimativas, o mercado global da VP irá crescer 9,2% até o ano de 2027, principalmente impulsionado pelas mudanças climáticas e suas consequências negativas na produção e qualidade da uva, demandando que os produtores e a indústria se adaptem, não somente para melhorar a qualidade dos vinhos, mas também para atingir a sustentabilidade da produção através do avanço tecnológico (IMARC, 2023).

Os viticultores identificaram os principais fatores/dificuldades existentes que impedem a adoção da VP, sendo o custo inicial o mais limitante para a implementação das ferramentas tecnológicas (68%). O segundo fator limitante foi a interpretação e aplicação dos resultados encontrados, apontado por 28% dos viticultores, seguido pelo fator falta de informações como uma dificuldade na implementação (24%) (Figura 4)

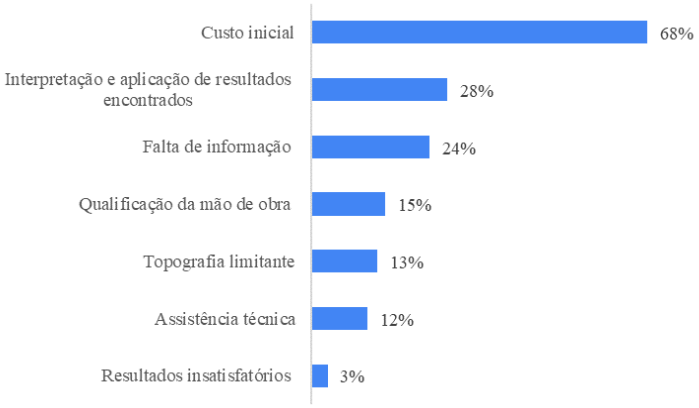


FIGURA 4 - Principais dificuldades na adoção de VP pelos viticultores.

Destaca-se que 64% dos entrevistados indicaram que não recebem qualquer tipo de assistência técnica. Isso pode sugerir a existência de um problema a ser abordado, tanto para promover uma maior difusão e adoção da VP, quanto para aprimorar o manejo técnico dos vinhedos. A falta de acesso à assistência técnica pode ser um obstáculo significativo para a implementação bem-sucedida da tecnologia na viticultura. Entretanto, a Empresa de Assistência Técnica e Extensão Rural (Emater), é atuante em todos municípios que foram citados nessa pesquisa, de forma que poderia atuar juntamente com instituições públicas ou privadas no auxílio da difusão da VP, através de palestras, cursos e dias de campo para os produtores assistidos, apontando assim uma lacuna que pode ser

preenchida futuramente. Essas informações são corroboradas por Bernardi e Inamasu (2014), quando observaram que consultores e cursos/treinamentos foram as principais fontes de informação para os produtores que adotam a AP no Brasil em geral.

CONCLUSÃO

Diante dos resultados obtidos através dessa pesquisa sobre a adoção da VP no setor vitivinícola gaúcho, torna-se evidente que a VP aparece como um tema de considerável relevância. A significativa familiaridade demonstrada pelos vitivinicultores, com 81% dos participantes indicando conhecimento sobre a VP, destaca a crescente importância que essa abordagem vem adquirindo no manejo dos vinhedos. No cenário atual, marcado por uma forte concorrência nos mercados nacional e internacional de vinhos, bem como pelo aumento dos custos de produção, a VP revela-se uma estratégia crucial. A constatação de que a maioria dos produtores, ainda não adota ferramentas de AP em seus cultivos, sinaliza que a adoção da VP ainda se encontra em estágio inicial. Isso aponta para um cenário promissor para a VP no RS, uma vez que, pode acarretar em mudanças significativas no setor vitivinícola, impulsionadas por incentivos financeiros e técnicos, tanto do setor público quanto do privado, por meio de instituições e serviços de extensão rural.

REFERÊNCIAS

ANSELMI, A. A. Adoção da agricultura de precisão no Rio Grande do Sul. 2012. 105 f. Dissertação - Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, 2012.

BERNARDI, A. C. de C.; INAMASU, R. Y. Adoção da agricultura de precisão no Brasil. Em: AGRICULTURA DE PRECISÃO: RESULTADOS DE UM NOVO OLHAR. Brasília, DF: Embrapa, 2014. p. 559-577. E-book. Disponível em: http://www.alice.cnptia.embrapa.br/alice/handle/doc/1003682. Acesso em: 11 nov. 2023.

BOLFE, É. L. et al. Precision and Digital Agriculture: Adoption of Technologies and Perception of Brazilian Farmers. Agriculture, [s. l.], v. 10, n. 12, p. 653, 2020. Disponível em: https://www.mdpi.com/2077-0472/10/12/653. Acesso em: 18 nov. 2021.

MELLO, L. M. R.; MACHADO, C. A. E. Cadastro vitícola do Rio Grande do Sul: 2013 a 2015. Brasília, DF: Embrapa, 2017. E-book. Disponível em:

<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/176223/1/ebookA4-5.pdf.>. Acesso em: 1 out. 2021.

PEREIRA, G. E. et al. Panorama da produção e mercado nacional de vinhos espumantes. [s. l.], p. 12, 2020.

SHANG, L. et al. Adoption and diffusion of digital farming technologies - integrating farm-level evidence and system interaction. Agricultural Systems, [s. l.], v. 190, p. 103074, 2021. Disponível em: https://linkinghub.elsevier.com/retrieve/pii/S0308521X21000275. Acesso em: 3 dez. 2023

VARIABILIDADE ESPACIAL DE DIÓXIDO DE CARBONO EM UMA INSTALAÇÃO PARA GADO LEITEIRO DO TIPO COMPOST BARN

Joao Victor Aguiar [1]; Patricia Ferreira Ponciano Ferraz [2]; Jacqueline Cardoso Ferreira [3]; Franck Morais de Oliveira [4]; Gabriel Araujo e Silva Ferraz [5]

[1]Graduando. Universidade Federal de Lavras, Departamento de Zootecnia. Campus Universitário . 37200000 - Lavras, MG - Brasil. Universidade Federal de Lavras - UFLA; [2]Docente. Universidade Federal de Lavras, Departamento de Engenharia Agrícola. Campus Universitário . 37200000 - Lavras, MG - Brasil . Universidade Federal de Lavras - UFLA; [3]Pesquisadora. Universidade Federal de Lavras, Departamento de Engenharia Agrícola. Campus Universitário . 37200000 - Lavras, MG - Brasil . Universidade Federal de Lavras - UFLA; [4]Doutorando. Universidade Federal de Lavras, Departamento de Engenharia Agrícola. Campus Universitário . 37200000 - Lavras, MG - Brasil . Universidade Federal de Lavras - UFLA; [5]Docente. Universidade Federal de Lavras, Departamento de Engenharia Agrícola. Campus Universitário . 37200000 - Lavras, MG - Brasil . Universidade Federal de Lavras - UFLA

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

A bovinocultura leiteira, uma das atividades agrícolas mais importantes do mundo, influencia diretamente na economia e desenvolvimento de um país. No entanto, apresenta um papel significativo sobre o as emissões de gases do efeito estufa, como o dióxido de carbono (CO2) e consequentemente sobre o aquecimento global. O objetivo deste trabalho foi identificar a variabilidade espacial e quantificar as emissões de CO2 e do Índice de Temperatura e Umidade (ITU) em uma instalação do tipo Compost Barn. O estudo foi realizado em novembro de 2023, em uma instalação com dimensões de 54 x 22 x 4,5 m (comprimento x largura x altura) com 86 vacas em lactação. Os dados foram coletados em cada ponto, em intervalos de dez segundos, durante um minuto, em duas alturas diferentes acima da superfície da cama, 0,25 m e 1,5 m, num total de 80 pontos distribuídos em um espaçamento de 3,2 metros no sentido do comprimento e 4,0 metros no sentido da largura. Os dados foram submetidos à análise geoestatística e à elaboração de mapas de krigagem. A análise geoestatística permitiu a variabilidade espacial para as condições ambientais. Na altura de 0,25 m, os valores do Índice de Temperatura e Umidade (ITU) variaram de 71,8 a 75,8, enquanto os níveis de CO2 variaram de 460 a 560 ppm. Na altura de 1,5 m, o ITU variou de 70 a 75, com os níveis de CO2 variando de 380 a 455 ppm. As análises viabilizaram o mapeamento das condições ambientais da instalação, com foco no bem-estar animal e na sustentabilidade da produção de leite.

PALAVRAS-CHAVE: bovinocultura leiteira; gases de efeito estufa; monitoramento ambiental

ABSTRACT

Dairy cattle farming, one of the most important agricultural activities in the world, directly influences the economy and development of a country. However, it plays a significant role in greenhouse gas emissions, such as carbon dioxide (CO2), and consequently in global warming. The objective of this work was to identify spatial variability and quantify CO2 and Temperature and Humidity Index (ITU) emissions in a Compost Barn type installation. The study was carried out in November 2023, in a facility measuring 54 x 22 x 4.5 m (length x width x height) with 86 lactating cows. Data were collected at each point, at intervals of ten seconds, for one minute, at two different heights above the bed surface, 0.25 m and 1.5 m, in a total of 80 points distributed at a spacing of 3.2 meters lengthwise and 4.0 meters widthwise. The data was subjected to geostatistical analysis and the creation of kriging maps. Geostatistical analysis allowed for spatial variability for environmental conditions. At a height of 0.25 m, Temperature and Humidity Index (ITU) values ranged from 71.8 to 75.8, while CO2 levels ranged from 460 to 560 ppm. At the height of 1.5 m, the THI ranged from 70 to 75, with CO2 levels

ranging from 380 to 455 ppm. The analyzes made it possible to map the environmental conditions of the facility, focusing on animal welfare and the sustainability of milk production.

KEYWORDS: ;

INTRODUÇÃO

A bovinocultura leiteira exerce grande influência no produto interno bruto de um país e representa uma das commodities agrícolas mais importantes do mundo (Üçtug, 2019). Segundo a Organização para a Cooperação e Desenvolvimento Econômico (OCDE), a projeção do crescimento da produção de leite no mundo tende a crescer 1,6% ao ano, destacando fatores importantes como o crescimento do rebanho, progressão de mercado e alternativas para redução de gases do efeito estufa (OECD /FAO, 2020).

Reconhecer que o aumento do rebanho desempenha um papel significativo sobre o aquecimento global é crucial para mitigar a emissão de gases de efeito estufa (GEE's). Estratégias como a aplicação de modelos biofísicos para simulação na pecuária, tem sido amplamente explorado com o objetivo de quantificar os prejuízos das mudanças climáticas e estimar como os animais responderão as essas mudanças (Emediegwu et al., 2023). A exemplo, a detecção e mensuração de gases dentro dos sistemas pecuários são técnicas promissoras para mitigar as emissões e adotar uma produção mais sustentável.

O dióxido de carbono (CO2), é um dos principais agentes causadores do aquecimento global e sua emissão está relacionada aos resíduos gasosos provenientes da fermentação entérica, a respiração dos animais e ao uso de combustíveis fósseis na fazenda (Astuti et al., 2024; Zou et al., 2020; Acaravci et al., 2016; Hamilton et al., 2010). Outras fontes que contribuem para o aumento da emissão de CO2 são: o uso de fertilizantes e adubos na produção de alimentos forrageiros (Ouatahar et al., 2021), e a estratégia utilizada para o manejo dos dejetos dos animais (Grant et al., 2015).

Nos animais as concentrações elevadas de CO2 podem irritar o trato respiratório, prejudicando seu bem-estar e comprometendo a sustentabilidade da indústria de laticínios (Stokstad et al., 2020). De forma geral, as emissões excessivas provocam danos à saúde como irritação das vias aéreas, náuseas, vômitos e morte por asfixia (Damasceno, 2020), deterioração da qualidade ambiental (Liu et al., 2019), escassez de recursos e fenômenos meteorológicos extremos (Li et al., 2021).

Segundo Kiggundu et al. (2019), as técnicas utilizadas para mensurar e quantificar os GEE's, pode ser por modelagens ou medidas diretas no campo direto. A geoestatística é um recurso que permite examinar a variabilidade espacial para as condições ambientais e fisiológicas, analisando de forma precisa o ambiente em que os animais estão alojados. (Ferraz et al., 2020).

OBJETIVOS

Diante disso, o objetivo deste estudo foi de avaliar a variabilidade espacial e quantificar as emissões de CO2 e do Índice de Temperatura e Umidade (ITU) em uma instalação para gado leiteiro do tipo Compost Barn.

MATERIAL E MÉTODOS

O estudo foi realizado em novembro de 2023, em uma instalação do tipo Compost Barn, localizada no município de Lavras, em Minas Gerais. A instalação encontra-se em uma altitude de 920,62 metros, com coordenadas geográficas de 21°15' de latitude Sul e 45°09' de longitude Oeste.

A instalação está orientada no sentido Leste-Oeste e possui 54 metros de comprimento, 22 metros de largura (quatro metros referente ao corredor de alimentação, localizado na face norte) e 4,50 metros de altura (Fig.1).

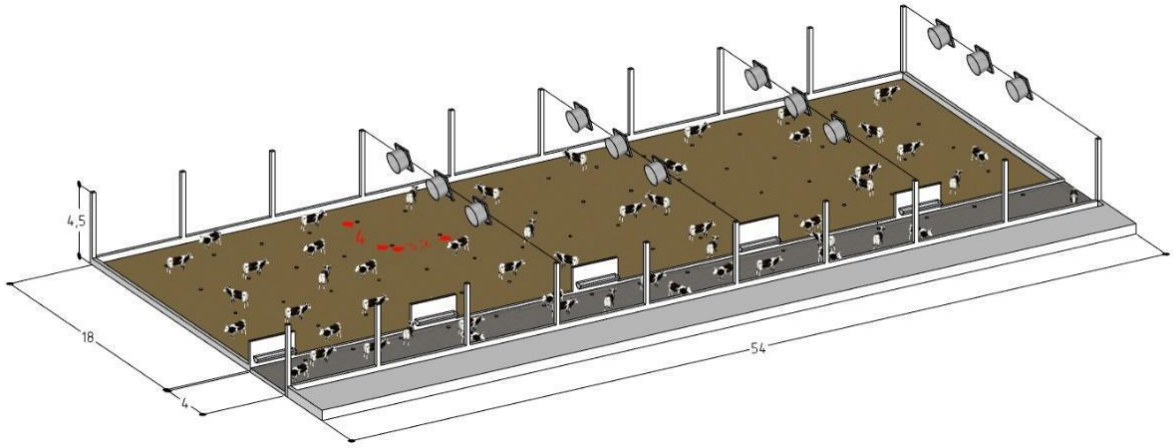


Figura 1. Perspectiva esquemática com as dimensões (metros) da instalação Compost Barn.

A instalação é aberta, sem muretas laterais, e com cobertura de telhas galvalume inclinadas a 30%. Os beirais possuem três metros de comprimento nas faces Norte e Sul, e de um metro nas faces Leste e Oeste. A instalação recebe ventilação forçada no sentido Oeste para Leste, a partir de 12 ventiladores axiais Ziehl-Abegg® que operam em alta velocidade e baixo volume (LVHS), distribuídos em quatro fileiras e a 2,5 metros de altura da cama. Os ventiladores possuem um diâmetro de 1,10 metros, três hélices que giram a 950 rpm, com potência de 0,86 kW e proporcionam um fluxo de ar de 23.000 m³·h-1. A cama de compostagem é de maravalha com uma profundidade de 65 cm, revolvida duas vezes ao dia, durante as ordenhas.

No dia da coleta dos dados a instalação acomodava 86 vacas em lactação, numa densidade de 13,81 m²/vaca. Os dados ambientais e a mensuração de CO2 foram coletados em cada ponto no intervalo de dez segundos, durante um minuto, nas alturas de 0,25 m e 1,5 m acima da superfície da cama. O gride utilizado foi de 80 pontos no espaçamento de 3,2 metros no sentido do comprimento e 4,0 metros no sentido da largura (Fig. 2).

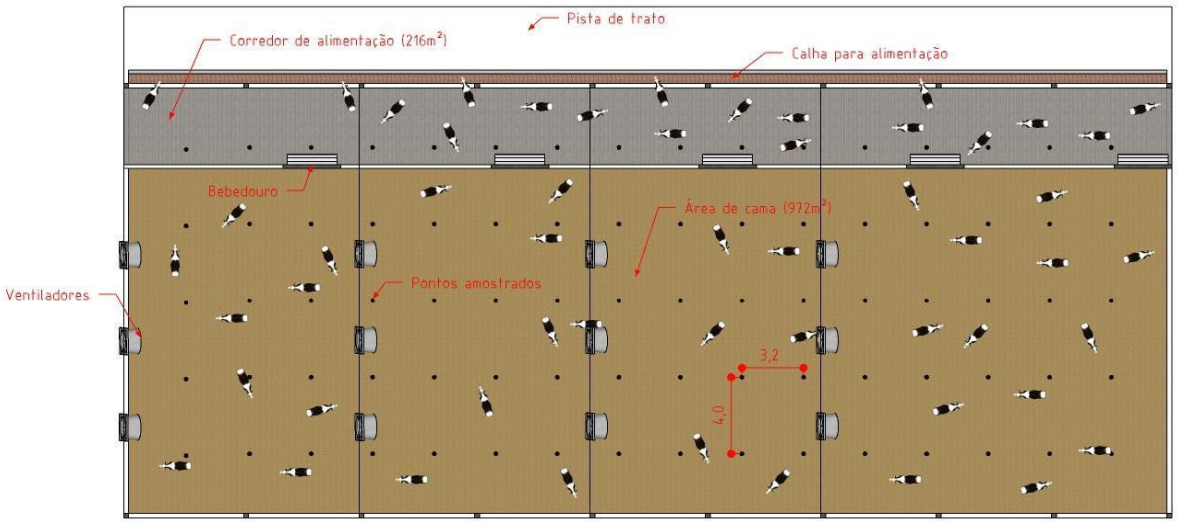


Figura 2. Layout das características construtivas e pontos amostrados (metros) no Compost Barn.

Para cálculo do ITU, a temperatura do bulbo seco (Tbs, °C), e a temperatura de ponto de orvalho (Tpo, °C) foram registradas pelo datalogger Hobo® MX2301A, com precisões de 0,2°C e 2,5%, respectivamente. A avaliação do ambiente térmico foi efetuada por meio da equação de Thom (1959):

$$ITU : T_{bs} + 0,36(T_{po}) + 41,5 \quad \text{Eq. (64)}$$

em que: ITU é índice de temperatura e umidade (admensional); Tbs é a temperatura de bulbo seco (°C); e Tpo é a temperatura de ponto de orvalho (°C).

A mensuração do dióxido de carbono (CO2) foi por meio de um protótipo, desenvolvido pela Universidade de Florença. A concepção do protótipo engloba quatro módulos distintos: unidades de medição de gases, processador, servidor e dashboard. A unidade de processamento é composta por um núcleo ARM Cortex M0+, um microcontrolador ATM2560 responsável pela transmissão de dados, além de um módulo Raspberry Pi Compute. A medição de CO2 (ppm) foi a partir do sensor SCD30, do tipo NDIR, com faixa de medição de 400 a 10000, que opera em temperaturas que variam de -40°C a 70°C e em uma umidade relativa de 0 a 95%.

Os dados adquiridos foram submetidos a análise geoestatística com o intuito de descrever a variabilidade espacial do CO2 e do ITU, utilizando o software R DEVELOPMENT CORE TEAM (2022). Esses dados foram submetidos à análise de semivariância para examinar a dependência espacial, seguida de interpolação através do método de krigagem ordinária. A semivariância foi obtida conforme a Equação 2 de Bachmaier e Backes (2008):

$$\hat{\gamma}(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(X_i) - Z(X_i + h)]^2 \quad \text{Eq. (65)}$$

em que: N (h) é o número de pares experimentais de observações Z(xi); e Z (xi + h) separados por uma distância h.

A semivariância foi ajustada utilizando o método da máxima verossimilhança restrita (MVR), resultando em estimativas menos enviesadas. Para esse ajuste, foi adotado o modelo matemático esférico, amplamente empregado em estudos geoestatísticos. Os parâmetros, incluindo efeito pepita (C0), variância da soleira (C0 + C1) e amplitude (a), foram derivados da equação de semivariância ajustada, conforme o comportamento dos gráficos. A qualidade do ajuste foi avaliada com base no grau de dependência espacial (GDS), seguindo a classificação que considera como fraca dependência espacial valores de GDS superiores a 75%, moderada entre 25 e 75%, e forte para valores de GDS inferiores a 25% (Cambardella et al., 1994).

Após os ajustes, os dados foram interpolados por meio de krigagem ordinária para facilitar a visualização dos padrões de distribuição espacial das variáveis na instalação. Os mapas resultantes foram gerados utilizando o software Surfer® 13. Esses mapas preveem o valor de uma variável em um ponto não amostrado por meio de interpolação e considerando a dependência espacial das informações obtidas nos demais pontos.

RESULTADOS E DISCUSSÃO

Os resultados do semivariograma aplicado na análise pode ser observado na Tabela 1.

Variável	Altura (m)	C_0	C_1	$C_0 + C_1$	a		GDE	EM	DP_{EM}	ER	S_{ER}
ITU	0,25	0	0,59	0,59	31,61	0	Forte	0,0003	0,271	0,0002	0,954
	1,50	0	0,44	0,44	31,59	0	Forte	-0.0003	0,236	-0,0007	0,939
CO_2	0,25	0	370,4	370,4	7,18	0	Forte	-0,0622	15,44	-0,0019	0,990
	1,50	124,08	123,64	247,72	33,38	50	Moderado	-0,0407	12,49	-0,0016	1,002

C_0 - efeito pepita; C_1 - contribuição; $C_0 + C_1$ - patamar; a – alcance e GDE - grau de dependência espacial; EM - erro médio; DP_{EM} - desvio padrão do erro médio; ER - erro reduzido; S_{ER} - desvio padrão do erro reduzido; REML - Método da Máxima Verossimilhança Restrita.

Tabela 1. Parâmetros estimados pelo método REML e modelo esférico dos semivariogramas experimentais para o Índice de Temperatura e Umidade Relativa (ITU) e o gás Dióxido de Carbono (CO2), durante cinco dias avaliados.

Os resultados das variáveis analisadas forneceram informações importantes como o Erro Médio (EM) e Erro Relativo (ER) que resultaram em valores próximos a zero e o Desvio Padrão do Erro Reduzido (SER) que resultou em valores próximo de 1,0, indicando uma boa execução (Ferraz et al., 2020).

Pela Tabela 1 verifica-se que as variáveis estudadas apresentam dependência espacial e uma distribuição não homogênea no espaço. A contribuição para a variável ITU, independente da altura, resultou em valores abaixo de 0,25 resultando em forte dependência espacial. O mesmo pode ser observado para a variável CO2 na altura de 0,25m, no entanto, na altura próximo aos animais (1,50 m) a dependência identificada foi do tipo moderada.

Com base nos valores estimados pela krigagem foram construídos os mapas de espacialização para cada variável e altura. A Figura 3 apresenta a variabilidade para o índice ITU.

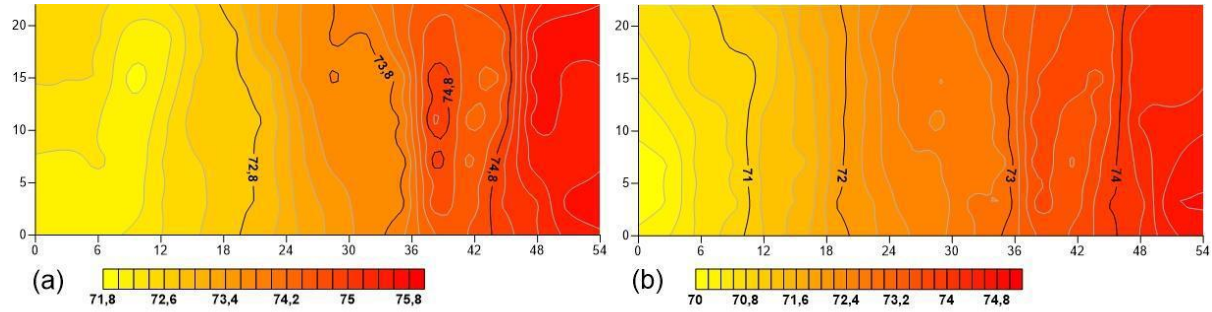


Figura 3. Variabilidade espacial para o Índice de Temperatura e Umidade (ITU) no Compost Barn a uma altura de 0,25 metros (a) e 1,5 metros acima da cama (b).

O ITU, nas duas alturas, apresentou comportamento semelhante, com aumento gradual no sentido de Oeste para Leste da instalação. Na altura de 0,25 m acima da cama os valores do ITU variaram de 71,8 a 75,8, enquanto na altura de 1,5 m, a variação foi de 70 a 75. Valores do ITU inferiores a 72 são considerados ideais para zona de conforto térmico em vacas leiteiras; e entre 72 e 79 são valores considerados levemente estressantes (Armstrong, 1994). A Figura 3 (a e b), sugerem um ambiente predominantemente classificado como levemente estressante. O estresse por calor está diretamente ligado à redução do tempo em que a vaca permanece deitada, devido à necessidade de expor a superfície corporal, causando queda da produção de leite (Moore et al., 2024; Reuscher et al., 2023). A presença de baixos valores para o ITU na região Oeste da instalação está relacionada à presença da ventilação mecânica na área.

A Figura 4 apresenta os mapas que indicam a dispersão de CO2.

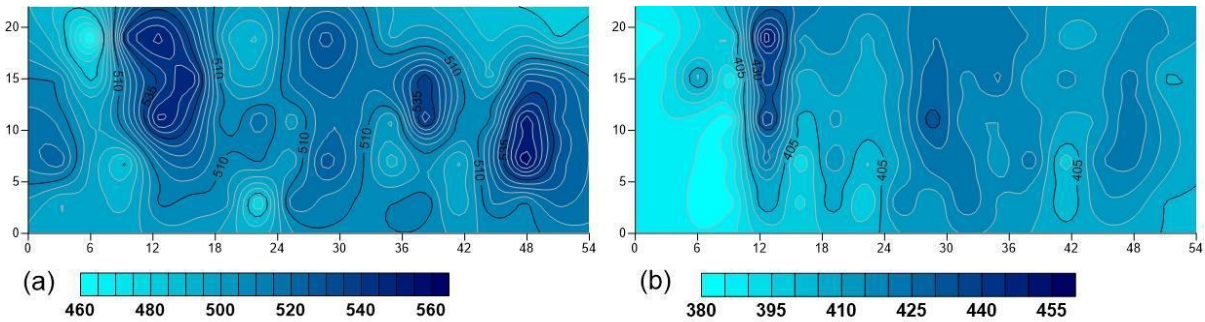


Figura 4. Variabilidade espacial do dióxido de carbono (CO2) no Compost Barn a uma altura de 0,25 metros (a) e 1,5 metros acima da cama (b).

Na altura de 0,25 m, obteve-se valores que variaram de 460 a 560 ppm, já na altura de 1,5 m a variação foi de 380 a 455 ppm. É perceptível que a concentração do gás foi maior com o sensor mais próximo da cama, predominando áreas com concentrações acima de 510 ppm. Jungbluth et al. (2001) apontou em seus estudos que a concentração de CO_2 na instalação deve variar entre 970 ppm e 1480 ppm. A análise indicou que os resultados apresentaram concentrações abaixo desse limite, independente da altura avaliada, podendo estar associada ao tipo de instalação, número de animais, gestão de dejetos e fermentação entérica (Mariantonietta et al., 2018).

A dispersão do CO_2 diminui à medida que aumenta a altura de coleta, reforçando que a decomposição do material utilizado para cama e a concentração dos dejetos podem agravar as emissões de GEE quando não há uma boa gestão dos resíduos da produção leiteira.

CONCLUSÃO

Os mapas de variabilidade espacial permitiram identificar a heterogeneidade para as variáveis estudadas. Nesse levantamento o ambiente pode ser considerado levemente estressante para o ITU, sendo registrados valores maiores a uma altura de 0,25 m da cama. A dispersão de CO2 diminuiu com o aumento da altura de coleta, sendo que os valores altos podem estar relacionados à proximidade da cama em decomposição, que é a principal fonte de emissão do referido gás. As análises permitiram mapeamento das condições ambientais da instalação, visando identificar estratégias para o bem-estar animal e a sustentabilidade da produção, frente às emissões de CO2.

AGRADECIMENTOS

À Fundação de Amparo à pesquisa do Estado de Minas Gerais (FAPEMIG - APQ-01082-21, BPD-00034-22) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq - 404420/2021-4).

REFERÊNCIAS

ACARAVCI, A.; ERDOGAN, S. The convergence behavior of CO2 emissions in seven regions under multiple structural breaks. International Journal of Energy Economics and Policy, v. 6, n. 3, p. 575-580, 2016.

ARMSTRONG, D. Heat stress interaction with shade and cooling. Journal of dairy science, v. 77, n. 7, p. 2044-2050, 1994. https://doi.org/10.3168/jds.S0022-0302(94)77149-6

ASTUTI, P. K.; AYOOB, A.; STRAUSZ, P.; VAKAYIL, B.; KUMAR, S. H.; KUSZA, S. Climate change and dairy farming sustainability; a causal loop paradox and its mitigation scenario. Heliyon, 2024. https://doi.org/10.1016/j.heliyon.2024.e25200

BACHMAIER, M.; BACKERS, M. Variogram or semivariogram? understanding the variances in a variogram. Precision Agriculture 9(1). 173-175, 2008. doi:10.1007/s11119-008-9056-2

CAMBARDELLA, C.A., MOORMAN, T.B., NOVAK, J.M., PARKIN, T.B., KARLEN, D.L., TURCO, R.F.; KONOPKA, A.E. Field scale variability of soil properties in Central Iowa soils. Soil Science Society of America Journal 58(5). 1501-1511, 1994. doi: 10.2136/sssaj1994.03615995005800050033x

DAMASCENO, F.A. Compost barn como alternativa para a pecuária leiteira. 1ª ed. Divinópolis: Adelante. 396p. 2020.

EMEDIEGWU, L. E.; UBABUKOH, C. L. Re-examining the impact of annual weather fluctuations on global livestock production. Ecological Economics, v. 204, p. 107662, 2023. https://doi.org/10.1016/j.ecolecon.2022.107662

FERRAZ, P. F. P.; GONZALEZ, V. C.; FERRAZ, G. A. S.; DAMASCENO, F. A.; OSORIO, J. A. S.; CONTI, L. Assessment of spatial variability of environmental variables of a typical house of laying hens in Colombia: Antioquia state Case. Agronomy Research 18(S2), 1244-1254, 2020. https://doi.org/10.15159/ar.20.099

GRANT, R. H.; BOEHM, M. T.; BOGAN, B. W. Methane and carbon dioxide emissions from manure storage facilities at two free-stall dairies. Agricultural and Forest Meteorology, v. 213, p. 102-113, 2015. https://doi.org/10.1016/j.agrformet.2015.06.008

HAMILTON, S.W.; DEPETERS, E.J.; MCGARVEY, J.A.; LATHROP, J.; MITLOEHNER, F.M. Greenhouse Gas, Animal Performance, and Bacterial Population Structure Responses to Dietary Monensin Fed to Dairy Cows. J. Environ. Qual. 39, 106-114, 2010. https://doi.org/10.2134/jeq2009.0035

JUNGBLUTH, T., HARTUNG, E.; BROSE, G. Greenhouse gas emissions from animal houses and manure stores. Nutrient Cycling in Agroecosystems 60, 133-145, 2001. https://doi.org/10.1023/A:1012621627268

KIGGUNDU, N.; DDUNGU, S. P.; WANYAMA, J.; CHEROTICH, S.; MPAIRWE, D.; ZZIWA, E.; MUTEBI, F.; FALCUCCI, A. Greenhouse gas emissions from Uganda's cattle corridor farming systems. Agricultural systems, v. 176, p. 102649, 2019. https://doi.org/10.1016/j.agsy.2019.102649

LI, M.; LIU S.; SUN Y.; LIU Y. Agriculture and animal husbandry increased carbon footprint on the Qinghai-Tibet Plateau during past three decades. J Clean Prod. 278:12396, 2021. doi: 10.1016/j.jclepro.2020.123963

LIU, D.; GUO X.; XIAO B. What causes growth of global greenhouse gas emissions? Evidence from 40 countries. Sci Total Environ. 661:750-66, 2019. doi: 10.1016/j.scitotenv.2019.01.197

MARIANTONIETTA, F.; ALESSIA, S.; FRANCESCO, C.; GIUSTINA, P. GHG and cattle farming: CO-assessing the emissions and economic performances in Italy. Journal of Cleaner Production, v. 172, p. 3704-3712, 2018. https://doi.org/10.1016/j.jclepro.2017.07.167

MOORE, S. S.; COSTA, A.; PENASA, M.; DE MARCHI, M. Effects of different temperature-humidity indexes on milk traits of Holstein cows: a 10-yr retrospective study. Journal of Dairy Science, 2024. https://doi.org/10.3168/jds.2023-23723

ORGANISATION FOR ECONOMIC CO-OPERATION AND DEVELOPMENT (OECD); FOOD AND AGRICULTURE ORGANIZATION FAO (FAO). Agricultural Outlook 2020-2029, OECD Publishing, Paris/FAO, Rome, 2020. https://doi.org/10.1787/1112c23b-en.

OUATAHAR, L.; BANNINK, A.; LANIGAN, G.; AMON, B. Modelling the effect of feeding management on greenhouse gas and nitrogen emissions in cattle farming systems. Science of the Total Environment, v. 776, p. 145932, 2021. https://doi.org/10.1016/j.scitotenv.2021.145932

REUSCHER, K. J.; COOK, N. B.; DA SILVA, T. E.; MONDACA, M. R.; LUTCHERHAND, K. M.; VAN OS, J. M. Effect of different air speeds at cow resting height in freestalls on heat stress responses and resting behavior in lactating cows in Wisconsin. Journal of Dairy Science, v. 106, n. 12, p. 9552-9567, 2023. https://doi.org/10.3168/jds.2023-23364

STOKSTAD, M.; KLEM, T.B.; MYRMEL, M.; OMA, V.S.; TOFTAKER, I.; OSTERÅS, O.; NODTVEDT, A. Using biosecurity measures to combat respiratory disease in cattle: The Norwegian control program for bovine respiratory syncytial virus and bovine Coronavirus. Front. Vet. Sci. 2020, 7, 167. https://doi.org/10.3389/fvets.2020.00167

THOM, E.C. The discomfort index. Weatherwise 12. 57-59, 1959.

ÜÇTUG, F. G. The environmental life cycle assessment of dairy products. Food Engineering Reviews, v. 11, n. 2, p. 104-121, 2019. https://doi.org/10.1007/s12393-019-9187-4

ZOU, B.; SHI, Z.X.; DU, S.H. Gases emissions estimation and analysis by using carbon dioxide balance method in natural-ventilated dairy cow barns. Int J Agric & Biol Eng, 13, 41-47, 2020. https://doi.org/10.25165/j.ijabe.20201302.4802

MODELAGEM DINÂMICA DA QUEDA DA SEMENTE DE SOJA EM SEMEADORAS DE PRECISÃO E IMPLICAÇÕES PARA A EQUIDISTÂNCIA LONGITUDINAL EM PLANTIO

Bruno Garlet Alberti [1]; Vinicius Kaster Marini [2]

[1]Graduando. Av Roraima 1000 Prédio 07 sala 120. Curso de Graduação em Engenharia Mecânica, Centro de Tecnologia, Universidade Federal de Santa Maria; [2]Docente. Av Roraima 1000 Prédio 10 sala 401. Departamento de Engenharia Mecânica, Centro de Tecnologia, Universidade Federal de Santa Maria

Apresentado no

Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024

Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO

O emprego de metodologias de modelagem dinâmica para ajudar no desenvolvimento de projetos de produtos no setor de máquinas agrícolas pode colaborar para alcançar resultados e produtos mais eficazes. O objetivo geral deste trabalho é estudar funcionalidades de semeadura que entregam atributos relacionados à dosagem e entrega de semente de soja sobre o sulco de semeadura de maneira uniforme. Para o alcance deste objetivo, este estudo envolve: (1) o estudo das funcionalidades de dosagem e condução de sementes em semeadores de precisão; (2) a implementação de modelo analítico para predizer o comportamento em queda da semente de soja individualizada em uma semeadora de precisão; (3) análise comportamental da trajetória da semente e o desempenho perante variações de velocidades de semeadura. Por fim, foi identificado um maior número de colisões da semente no interior das paredes do tubo condutor, em consequência ao incremento da velocidade de deslocamento da semeadora. Os resultados mostram que o desempenho de sistemas de dosadores pneumáticos de discos verticais diminui com o aumento da velocidade considerando a condução da semente até o sulco de semeadura em queda livre, ou seja, sob influência de força da gravidade.

PALAVRAS-CHAVE: Semeadura precisa; Dosadores e condutores; Semeadora de precisão

ABSTRACT

The use of dynamic modeling methodologies to help develop product designs in the agricultural machinery sector can help achieve more effective results and products. The general objective of this work is to study sowing functionalities that deliver attributes related to the dosage and delivery of soybean seed over the sowing furrow in a uniform manner. To achieve this objective, this study involves: (1) the study of seed dosing and seed guidance functionalities in precision seeders; (2) the implementation of an analytical model to predict the falling behavior of individual soybean seeds in a precision seeder; (3) behavioral analysis of the seed trajectory and performance in the face of variations in sowing speeds. Finally, a greater number of seed collisions were identified within the walls of the conductor tube, resulting in an increase in the seeder's travel speed. The results show that the performance of vertical disc pneumatic metering systems decreases with increasing speed considering the seed being conveyed to the sowing furrow in free fall, that is, under the influence of gravity.

KEYWORDS: ;

INTRODUÇÃO

Segundo Bellé et al. (2018), o estabelecimento das culturas, e as tecnologias de semeadura são aspectos influenciadores no rendimento e na produtividade. Em vista disso, a semeadura torna-se um dos fatores primordiais que influencia o rendimento das culturas, assim como os equipamentos utilizados no processo. Um plantio preciso é fundamental na eficiência do uso da terra, pois todo o processo produtivo depende dos resultados alcançados durante essa operação. Por essa razão, a

pesquisa em mecanismos e tecnologias que possibilitem um plantio mais preciso tem sido de grande interesse nas últimas décadas, especialmente devido à tendência contínua de crescimento da produção agrícola brasileira, com projeções futuras promissoras.

Nesse contexto, cresce a necessidade por mecanismos que possibilitam melhor plantabilidade no âmbito de performance no campo. Assim, torna-se motivo de grande interesse nas últimas décadas, visto que a tendência da produção brasileira está em constante crescimento ano após ano. De acordo com CONTE (2017), plantabilidade é sinônimo de precisão no plantio, ou seja, é a quantidade de semente com o mesmo espaçamento por área e com à mesma profundidade. Por esse motivo, o desenvolvimento de semeadoras com tecnologia de ponta está em alta demanda, visando aprimorar a inteligência de plantio sobre as linhas da semeadora. Essa inteligência permite que as sementes sejam depositadas no sulco de plantio de forma regular e posicionadas em condições ideais de crescimento, otimizando o estabelecimento da lavoura.

OBJETIVOS

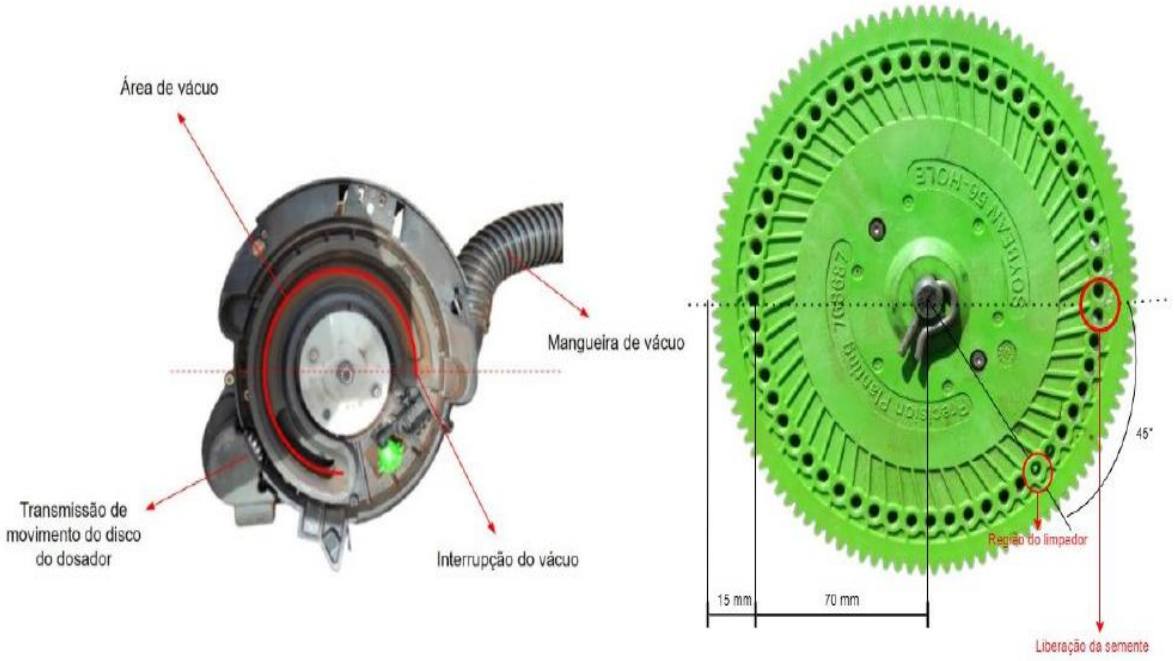
A interpretação sobre o desenvolvimento de semeadoras precisas considera métricas de capacidade e eficiência, como também avalia recursos funcionais disponibilizados pelo propósito das soluções para otimizar a entrega de parâmetros de atuação de semeadura. Nesse contexto, a verificação dos requisitos aplicáveis ao projeto pode ser orientada pelas características e os fatores que influenciam na qualidade da semeadura. Esses fatores são percebidos como fatores de influência no projeto (ROMANO, 2003; MARINI, 2007), pela caracterização de diversos elementos presentes no meio onde as máquinas agrícolas estão inseridas, que influenciam o desempenho da operação.

Este trabalho consiste em avaliar o desempenho de semeadoras de precisão para diferentes condições de velocidades entre dosador e velocidade de solo. O objetivo é determinar o comportamento dinâmico da semente desde o processo de singulação pelo dosador pneumático de disco vertical, até o percurso de queda livre após a semente ser dosada, considerando variações de velocidades de deslocamento de 4 km/h, 5 km/h, 6 km/h, 7 km/h e 8 km/h para a semeadora.

MATERIAL E MÉTODOS

A abordagem do estudo trata de uma análise investigativa sobre os meios de funcionamento de semeadoras precisas e a forma de dosagem/singulação e entrega de semente ao sulco, a elaboração dinâmica parte de algumas considerações necessárias. Para isso, foi utilizado como base analítica um dosador de disco vertical pneumático com utilização de disco alveolado para o cultivo de soja, cujo apresenta 56 furos (alvéolos) com diâmetro de aproximadamente 4 mm. Além disso, o disco apresenta diâmetro total de 170 mm e distância entre o centro do eixo central e o centro do alvéolo é de 70 mm. Verifica-se que o ponto de liberação da semente é exatamente na interrupção do vácuo que é exatamente a 0° com o eixo horizontal como mostra a Figura 1.

FIGURA 1 - Características do dosador e disco de sementes de soja.



Fonte: Arquivo do autor.

Observa-se que há uma área de vácuo de aproximadamente 270° em relação a linha horizontal tracejada, isso faz com que o ponto de liberação da semente seja no momento de interrupção de vácuo que é exatamente no eixo horizontal fazendo com que a semente apresente componentes de velocidade e deslocamento horizontal, assumindo velocidade vertical após sofrer influências da força da gravidade quando está sujeita a trajetória de queda livre. Para o desenvolvimento analítico foram realizadas algumas considerações de simplificação que estão descritas neste contexto elaborado:

I. O grão de soja é considerado perfeitamente esférico.

II. A massa do grão de soja é igualmente distribuída em todo o seu volume.

III. O grão de soja é perfeitamente vinculado ao alvéolo do dosador enquanto se encontra na cavidade do disco dosador.

IV. O grão de soja descreve o movimento bidimensional de queda livre, este modelado de maneira conservativa, simulando queda de uma única semente por vez.

V. Interações do grão com elementos da semeadora são entendidas em função de quantidade de movimento.

VI. O referencial para desenvolvimento analítico dinâmico é considerado o próprio carro de linha com componentes totalmente fixados.

VII. Despreza-se também vibrações e deslocamentos externos quaisquer, tais como as vibrações do carro de linha.

O primeiro passo da modelagem é a decomposição das velocidades da semente em função da velocidade do disco dosador, porém a velocidade do disco do dosador é completamente influenciada pela velocidade de semeadura e densidade de semente por área. Dessa maneira, assume-se que a velocidade da semente é igual a velocidade angular do disco dosador até o instante anterior a ela ser liberada pela interrupção do vácuo. Após a semente ser liberada do disco dosador, ela assume

componentes de velocidade horizontal em função da velocidade de semeadura e velocidade horizontal em função da força da gravidade. Com isso, obtém-se a trajetória da semente da semente com as características próximas de uma parábola, através de uma equação do segundo grau como mostrada abaixo:

$$\left(\frac{-g}{2 \cdot Vsx^2}\right) \cdot X^2 + \left(\frac{Vsy}{Vsx}\right) \cdot X + (Yo) = 0 \qquad (1)$$

Após assumir a trajetória de queda livre pelo interior do tubo condutor, a semente sofre colisões com as paredes internas do tubo, fazendo com que sua além da mudança de trajetória, dissipa sua energia após cada colisão, por consequência reduzindo a sua velocidade. No entanto, há um certo número de colisões, que fazem com que a semente perca grande parte da sua energia cinética e venha a cessar as colisões por conta de que seu deslocamento no eixo "x" seja menor que o raio da semente de soja. Tomando esse fator como premissa, encontrou-se o número de colisões da semente para diferentes velocidades de deslocamento da semeadora.

Por isso, no instante final da última colisão, assume-se que a semente passa a se mover em rolamento perfeito, sem deslizamento, percorrendo assim a trajetória da porção final da geometria do tubo condutor. Para isso, utilizou-se a 2° Lei de Newton para o balanceamento das energias, visando encontrar a velocidade final da saída da semente sobre o tubo condutor e a velocidade com que a semente impacta sobre o solo.

Além do número de colisões identificou-se a possibilidade de rolamento da semente havendo a condução da semente ocasionando incremento de velocidade, ou seja, as colisões geram diminuição da velocidade em função do coeficiente de restituição da semente com o tubo condutor enquanto o rolamento ocasiona o aumento da velocidade da semente ao ser conduzida. A equação do rolamento perfeito para a semente pelo interior do tubo condutor é apresentada abaixo:

$$V_f^2 = Vo^2 + 2 \cdot \frac{g \cdot sen\,\theta}{\left(1 + \frac{I_{cm}}{m \cdot rs^2}\right)} \cdot L \qquad (2)$$

RESULTADOS E DISCUSSÃO

Os resultados identificados mostram uma leve variação na altura das colisões em proporção à velocidade de partida da semente desde o disco dosador, fato que se comprova pela velocidade de deslocamento da semente serem diferentes para distintas velocidades de semeaduras. Também foi visto que, enquanto para as velocidades de deslocamento 4 km/h e 5 km/h a semente colide 3 vezes no interior do tubo, para as velocidades de 6 km/h, 7 km/h e 8 km/h ocorre 4 colisões, fator que aumenta com o incremento da velocidade de semeadura.

Verificou-se a redução da velocidade da semente após as colisões para cada velocidade de semeadura analisada e o aumento da velocidade após o rolamento da semente. A Figura 2 mostra uma ilustração da trajetória da semente em função das colisões ocasionadas pelo aumento da velocidade de semeadura, ou seja, o aumento da velocidade de semeadura ocasiona um aumento no número de colisões da semente no interior do tubo gerando atraso ou antecipação das mesmas, fato também identificado em Copetti (2003).

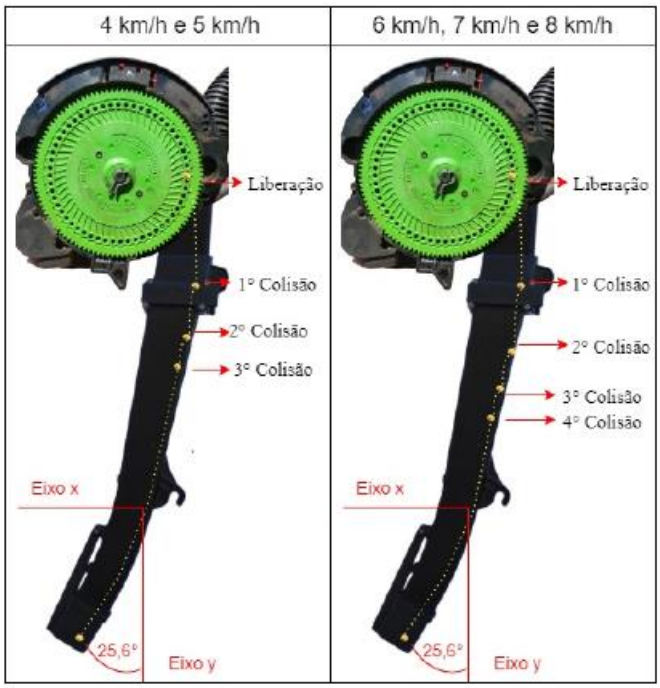


FIGURA 2 - Variação da trajetória da semente em função do número de colisões no interior do tubo condutor.

Fonte: Elaborado pelo autor.

De modo geral, a Tabela 1 expressa os resultados obtidos para o desenvolvimento analítico da trajetória da semente de soja.

TABELA 1 - Predição da velocidade de queda da semente em função da posição para distintas velocidades de semeadura, segundo modelo determinístico deste trabalho.

		Velocidade da semente (m/s)				
Posição	**Velocidade de semeadura**	**4 km/h**	**5 km/h**	**6 km/h**	**7 km /h**	**8 km/h**
0	Liberação do disco dosador	1,538	1,540	1,542	1,545	1,549
1	1° Repique	0,929	0,930	0,932	0,933	0,935
2	2° Repique	0,561	0,562	0,563	0,564	0,565
3	3° Repique	0,339	0,339	0,340	0,341	0,341
4	4° Repique	-	-	0,205	0,206	0,206
		Velocidade de rolamento perfeito sem deslizamento (m/s)				
5	Vel. Sem. Saída do Tubo	2,044	2,368	2,088	1,992	1,891
6	Vel. Sem. Impactar o Solo	2,145	2,489	2,224	2,134	2,040
		Energia Cinética da semente na saída do tubo condutor (J)				
		3,76E-04	5,05E-04	3,92E-04	3,57E-04	3,22E-04

Fonte: Elaborado pelo autor.

A semente entregue sobre o sulco de semeadura também sofre variações em seu deslocamento como por exemplo colisões e rolamento quando ocorre o primeiro contato com o solo. A Figura 3 mostra

uma predição de variação de equidistância da deposição de sementes de soja no sulco de semeadura em função da variação das velocidades, ou seja, representa como a semente é depositada e ilustra uma forma de contato semente/solo, demonstrando a semente mudando sua direção no instante em que colide com o solo e cessa seu movimento permanecendo então em sua posição final.

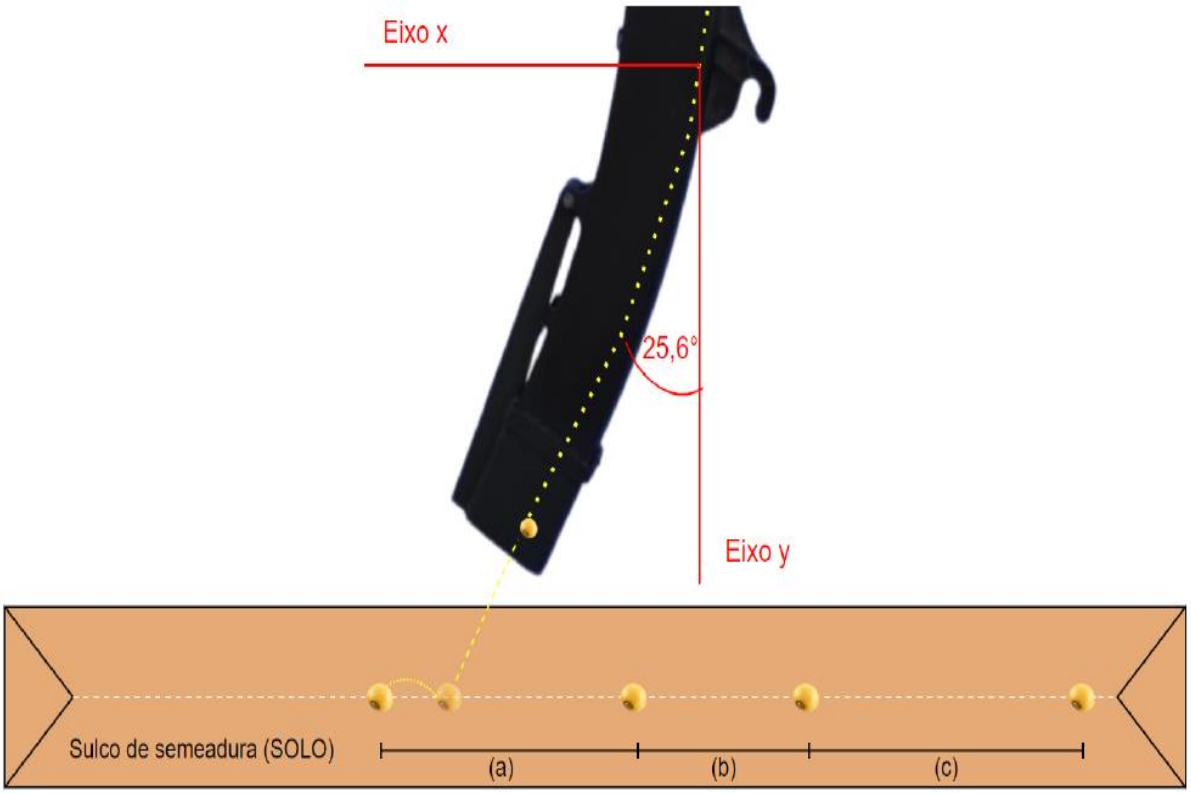


FIGURA 3 - Trajetória da semente ao sair do tubo condutor e impactar o solo.

Fonte: Elaborado pelo autor.

De modo geral, o aumento da velocidade de semeadura exige com que o disco do dosador seja aumentado para conseguir suprir a necessidade de entrega de semente por metro linear padronizada pelo monitor do sistema de controle. Esse aumento da velocidade faz com que a semente possua também velocidades maiores e por consequência maiores velocidades de semente no interior do tubo condutor gera maior número de colisões no interior do tubo condutor. Isto impede a distribuição homogênea em maiores velocidades, pois quanto maior o número de colisões das sementes, maior o tempo em queda livre, gerando imprecisão no plantio e deposição de sementes fora de distâncias esperadas entre si. Com consequente prejuízo à equidistância longitudinal de plantio, também ocorre perda de produtividade em razão da incerteza de espaçamento longitudinal resultante (HÖRBE; GRAVE, 2021).

CONCLUSÃO

O presente desenvolvimento analítico sobre a trajetória da semente de seja para dosador pneumático de disco vertical e tubo condutor de condução por gravidade permitiu identificar de forma analítica e determinística o comportamento da semente de soja desde o processo de dosagem e condução. A definição permitiu identificar o aumento do número de colisões no interior do tubo condutor conforme o incremento da velocidade de semeadura. Os resultados mostram que o desempenho de sistemas de dosadores pneumáticos de discos verticais diminui com o aumento da velocidade considerando a condução da semente até o sulco de semeadura em queda livre, ou seja, sob influência de força da gravidade.

AGRADECIMENTOS

Os autores agradecem ao programa FIT-BIT da UFSM, pelo suporte prestado a este estudo tecnológico em nível de graduação.

REFERÊNCIAS

BELLÉ, Leocemar Andrade et al. Influência de diferentes velocidades de semeadura no estabelecimento da cultura do milho (Zea mays L.). **Unoesc & Ciência-ACET**, v. 9, n. 2, p. 147-154, 2018. Acesso em: 23 fev. 2024.

CONTE, Osmar. **Máquinas para adubação e semeadura (Plantabilidade).** 2017. Embrapa Soja. Acesso em: 22 fev. 2024.

COPETTI, E. Plantadoras: culpa de quem? **Cultivar Máquinas**, v.3, n.18, p.14-17,2003. Acesso em: 23 out. 2023.

HÖRBE, Tiago de Andrade Neves; GRAVE, Fernando Luis. Entendendo a relação entre distribuição de plantas na linha e a produtividade de soja. **CCGL Pesquisa e Tecnologia**. Cruz Alta - RS, 2021. Acesso em: 03 set. 2023.

MARINI, V. K. **Fatores de influência e funções técnicas no projeto de máquinas agrícolas: uma contribuição teórica**. Dissertação de Mestrado-Santa Maria: Universidade Federal de Santa Maria, 2007.

ROMANO, L. N. **Modelo de Referência para o Processo de Desenvolvimento de Máquinas Agrícolas.** Tese de Doutorado-Florianópolis: Universidade Federal de Santa Catarina, 2003.

COMPETÊNCIAS NECESSÁRIAS AOS PROFISSIONAIS DA AGRICULTURA DIGITAL: REVISÃO DE LITERATURA E ENTREVISTAS

Lucia Maria Cuque [1]; João Augusto Mattar Neto [2]
[1]Bolsista. Pedagoga, Doutoranda - TIDD - Programa de Pós-Graduação em Tecnologias da Inteligência e Design Digital, PUC-SP, São Paulo, SP, Fone: (11) 3124-7216, lucia.cuque@gmail.com.. Pontifícia Universidade Católica de São Paulo; [2]Docente. Filosofia e Letras, Professor - TIDD - Programa de Pós-Graduação em Tecnologias da Inteligência e Design Digital, PUC-SP, São Paulo, SP.. Pontifícia Universidade Católica de São Paulo

Apresentado no
Congresso Brasileiro de Agricultura de Precisão e Digital - ConBAP 2024
Ribeirão Preto, SP, 25 a 27 de novembro de 2024

RESUMO
O objetivo deste artigo é comparar as competências necessárias aos profissionais da agricultura digital, identificadas por meio de revisão de literatura, com dados coletados por entrevistas. Este estudo busca responder à seguinte pergunta: quais competências são compreendidas como necessárias para o profissional que atua na agricultura digital, segundo diversos *stakeholders* no Brasil e a literatura científica? A metodologia envolveu revisão de literatura utilizando as bases de dados Scopus, Web of Science e Google Scholar, e entrevistas com representantes desses *stakeholders*. As competências identificadas pela pesquisa podem ser divididas em tecnológicas (como conhecimentos de tecnologias e ferramentas digitais e operação de equipamentos) e humanas (como gestão e liderança). Trabalhos futuros podem explorar outras competências presentes na literatura, como sustentabilidade.

PALAVRAS-CHAVE: competências digitais; Indústria 4.0; tecnologias digitais

ABSTRACT
This article aims to compare the competences needed by digital agriculture professionals, identified through a literature review, with data collected by interviews. This study seeks to answer the following question: what competencies are understood as necessary for the digital agriculture professional, according to various stakeholders in Brazil and the scientific literature? The methodology involved a literature review using the Scopus, Web of Science, and Google Scholar databases and interviews with representatives of these stakeholders. The competencies identified by the research can be divided into technological (such as knowledge of technologies and digital tools and equipment operation) and human (such as management and leadership). Future work may explore other competences in the literature, such as sustainability.

KEYWORDS: digital competences; Industry 4.0; digital technologies

INTRODUÇÃO

A digitalização e a disponibilização sem precedentes de imensa massa de dados digitais e capacidades analíticas transformou e melhorou a eficiência operacional dos sistemas agroalimentares (FAO, 2022). Diferentes termos são utilizados indistintamente na literatura para expressar a digitalização nos sistemas de produção agrícola, cadeias de valor e sistemas alimentares (Silveira *et al*., 2023), como agricultura inteligente, agricultura de precisão (AP), agricultura de decisão, agricultura digital (AD) e agricultura 4.0 (Klerkx; Jakku; Labarthe, 2019).

O sucesso da AD depende da capacidade dos *stakeholders* aplicarem suas tecnologias e técnicas no contexto de atuação. Segundo Michailidis *et al*. (2024), as habilidades e competências técnicas,

sociais e interpessoais são igualmente imprescindíveis para que os agricultores alcancem todo o potencial da AP. Essas competências incluem as capacidades técnicas e gerenciais, capacidade de interpretação de dados e informações, e habilidades para integrar tecnologias na prática agrícola e usá-las de forma eficiente.

O Brasil é um dos maiores produtores e exportadores mundiais de produtos agrícolas. O país está implantando a AD nas propriedades rurais, com o objetivo de manter a competitividade da agricultura no contexto global (Massruhá *et al*., 2020). Os produtores rurais brasileiros buscam soluções para desafios relacionados à AD, tais como: falta de conectividade à internet; custo de máquinas, equipamentos e aplicações; obtenção de mão de obra externa qualificada e especializada; custo de contratação de prestadores de serviços; acesso à formação dos profissionais em tecnologias de AD (Rossi Junior; Doyle, 2023); ausência das competências necessárias para a AD nos currículos do ensino agrícola, técnico e universitário (da Silveira *et al*., 2023); dentre outras.

Competências são compreendidas aqui como "um saber agir responsável e reconhecido, que implica mobilizar, integrar, transferir conhecimentos, recursos, habilidades, que agregam valor econômico à organização e valor social ao indivíduo" (Fleury; Fleury, 2001, p. 21). Conhecer as competências relevantes à consecução de objetivos organizacionais favorece processos associados à gestão de pessoas, como, diagnóstico de necessidades de capacitação e planejamento educacional (Brandão, 2023), além de estimular os profissionais a construírem seus projetos de carreira e desenvolvimento pessoal (Dutra, 2017).

OBJETIVOS

O objetivo deste artigo é comparar as competências necessárias aos profissionais da agricultura digital, identificadas por meio de revisão de literatura, com os dados coletados por entrevistas. Este estudo almeja responder à seguinte pergunta: quais competências (conhecimentos, habilidades e atitudes) são compreendidas como necessárias para o profissional que atua na agricultura digital, segundo diversos *stakeholders* no Brasil e a literatura científica?

MATERIAL E MÉTODOS

O primeiro método empreendido no contexto desta investigação, com o objetivo de conhecer, analisar e organizar as pesquisas documentadas por pesquisadores e profissionais, foi a revisão sistemática de literatura, que seguiu o processo proposto por Okoli (2019). A análise documental é uma técnica de pesquisa social recomendada para a identificação das competências (organizacionais e humanas) imprescindíveis para uma organização, visto que propicia o conhecimento do conteúdo público, significados e intenções subjacentes sobre o tema (Carbone; Brandão; Leite, 2006; Brandão, 2023).

Em 11 de fevereiro de 2023, foi realizada a ação de busca nas bases de dados dos sites Scopus, Web of Science e Google Scholar, das palavras: *agriculture OR agricultural digital OR digitalization OR 4.0 OR technology OR technologies competence OR competences OR competency OR competencies OR skill OR skills OR ICT OR ICTs*. Os resultados do mecanismo de pesquisa ficaram restritos somente às páginas com os termos especificados no título. Na busca, foram listados 55 artigos na Scopus, 17 no Web of Science e 340 no Google Scholar. Para a seleção prática dos artigos do estudo, critérios de inclusão e exclusão foram aplicados nas três bases (Mattar; Ramos, 2021), que resultou na escolha de 61 artigos para leitura completa e fichamento.

Concluída a etapa da revisão de literatura, que trouxe esclarecimentos sobre o estado atual da produção do conhecimento científico relativo ao tema da pesquisa, a técnica de entrevista foi escolhida para apoiar a coleta de dados no campo. A entrevista é uma técnica frequentemente aplicada ao mapeamento de competências (Brandão, 2023). Conhecer a opinião dos *stakeholders* é estratégica

para a definição das competências necessárias para a atuação do profissional da AD. O roteiro de perguntas foi elaborado segundo os critérios apontados pelo método de entrevista semiestruturada responsiva (Rubin; Rubin, 2011) e, na fase de teste, foi submetido à análise de três profissionais, representantes de diferentes *stakeholders* da AD brasileira. O instrumento para a entrevista foi validado no mês de agosto de 2023.

A identificação dos *stakeholders* da AD, no contexto da investigação, percorreu dois caminhos. O primeiro passo foi identificar os principais *stakeholders* através da revisão de literatura. O segundo caminho foi obter, nas entrevistas, indicações de outros *stakeholders* da AD.

Um total de 58 pessoas, que atuam profissionalmente em algum dos *stakeholders* da AD no Brasil, foram convidadas pelos autores para participar da pesquisa, sendo que 15 profissionais aceitaram o convite para a entrevista. Na seção de resultados, as falas dos entrevistados estão indicadas com a letra "E" mais um número, que pode variar de 1 a 15.

Os profissionais entrevistados trabalham nos seguintes *stakeholders* da AD: academia, associação de máquinas agrícolas, associação de bioenergia, fabricante de máquinas agrícolas, concessionária de máquinas agrícolas, fabricante de máquinas e equipamentos para armazenagem de grãos, serviços de tecnologia da informação para o agronegócio, governo brasileiro, instituição de pesquisa privada para a agricultura e biorrefinaria do setor sucroenergético.

Tendo em vista que alguns dos profissionais entrevistados informaram que suas famílias são produtores rurais, e que pessoalmente desenvolvem ou já desenvolveram atividades relacionadas à produção agrícola, é possível afirmar que o produtor rural também está contemplado no perfil dos *stakeholders* entrevistados.

Para compreender o ponto de vista dos entrevistados sobre as competências necessárias ao profissional da AD, foram realizadas algumas perguntas no contexto da entrevista. Os respectivos enunciados foram cuidadosamente elaborados para não sugerir ou apresentar nenhum conhecimento, habilidade ou atitude que pudesse influenciar a opinião do entrevistado. Este artigo apresentará os resultados obtidos especificamente com a questão: "quais são as competências (habilidades, atitudes e áreas de conhecimento) necessárias ao profissional da agricultura digital?".

As entrevistas foram realizadas por meio de ferramenta digital, especificamente o Google Meet; tiveram os seus áudios gravados, transcritos e analisados sem a utilização de nenhuma ferramenta ou *softwar*e. Os dados obtidos foram analisados segundo o método de codificação provisória proposto por Saldaña (2013).

A pesquisa, os documentos e o instrumento da entrevista foram aprovados pelo Comitê de Ética em Pesquisa (CEP) da Pontifícia Universidade Católica de São Paulo - PUC/SP, por meio do parecer consubstanciado CAAE: 73017923.9.0000.5482, no. parecer: 6.578.497.

RESULTADOS E DISCUSSÃO

Esta seção apresenta a análise dos dados coletados nas entrevistas realizadas e a discussão das informações por meio da triangulação dos dados obtidos nas entrevistas e em revisão de literatura.

A apresentação dos dados e a discussão foram organizados em três subseções, com os temas que contemplam os conhecimentos, habilidades e atitudes mais frequentemente mencionados pelos entrevistados como essenciais para o profissional da AD.

1 Conhecimentos necessários para a AD

Os conhecimentos mencionados pelos entrevistados foram agrupados por afinidade de significado em quatro temas. O tema tecnologias e ferramentas digitais reúne a maior parte dos conhecimentos mencionados, representando um total de 46% dos conhecimentos. O tema agronomia apresenta os conhecimentos que se relacionam à produção agrícola, somando 34% do total dos conhecimentos citados nas entrevistas. Máquinas agrícolas representam 7% dos conhecimentos apontados pelos profissionais. Outros conhecimentos foram citados apenas uma vez. A seguir são apresentados os resultados e discussões dos dois temas mais constantes nas respostas dos entrevistados, ou seja, tecnologias e ferramentas digitais e agronomia.

1.1 Conhecimentos de tecnologias e ferramentas digitais

Alguns entrevistados chamam a atenção para a geração de grande quantidade de dados pelas soluções de AD e a necessidade de os agricultores buscarem conhecimento sobre o assunto.

[...] E esse grande volume de dados, passou a ser chamado de *big data* [...] Isso impõe desafios também para os profissionais, inclusive se capacitarem nessas áreas. [...] (E9).

[...] Vai puxar muito para essa parte de informática que dependendo da área dentro da agricultura digital que ele que ele vai trabalhar, ele vai mexer muito com dados. [...]. Então ele vai precisar muito desse conhecimento, essa área nova que não tinha antes. [...] (E11).

Mayor *et al*. (2022), assim como E9 e E11, afirmam que os agricultores são grandes produtores de dados que, devido à falta de tratamento eficaz e competente, não são totalmente explorados. Weersink *et al*. (2018) alertam para a necessidade de os agricultores saberem lidar com os dados, pois o aumento da produtividade e melhoria ambiental são limitados pela falta de governança de dados e ausência de habilidades em lidar e interpretar dados no nível da fazenda.

Outros entrevistados manifestam preocupações sobre a necessidade de capacitação e atualização dos profissionais da AD nas novas ferramentas e tecnologias digitais.

[...] a questão de capacitação em tecnologias digitais, né, a qualificação de mão de obra, ela, ela sempre surge como um, um desafio ou uma dificuldade na difusão, na adoção e na difusão das tecnologias digitais, né? A capacitação, a qualificação de mão de obra em tecnologias digitais, né? [...] (E9).

[...] Esse *machine learning*, *deep learning*, cada vez mais a gente vai estar integrando máquinas virtuais com conhecimento, cada vez mais amplos para apoiar a tomada de decisão, seja na identificação de uma praga, de uma planta daninha, do melhor momento de fazer uma operação agrícola. Isso tem ocorrido numa velocidade, assim, muito grande. [...] (E14).

A FAO (2022), assim como E9 e E14, reforçam a necessidade de os agricultores serem educados sobre os assuntos relacionados às novas tecnologias e, também, treinados em como usar as novas ferramentas. Ayre *et al*. (2019) destacam que na agricultura inteligente, os agricultores(as), os consultores agrícolas e os fornecedores de *softwares* precisam de novas competências que os habilitem a adquirir, partilhar, gerar, interpretar, armazenar e combinar dados digitais da produção agrícola, para, assim, alcançar melhores decisões para a gestão.

1.2 Conhecimentos de agronomia

Os conhecimentos conceituais e experienciais relacionados à agronomia são os mais importantes na opinião de alguns entrevistados. Por exemplo, o aproveitamento dos benefícios que as soluções digitais podem oferecer depende do conhecimento que o próprio agricultor tem dos conhecimentos de agronomia e da produção agrícola.

Ele tem que entender do processo onde ele está envolvido, ele não precisa ser um entendedor da produção Agro mas do processo, dos processos que estão lá na produção Agro [...] tem sazonalidade, tem período de chuva, período de seca, tem sequência de culturas, tem risco, tem, ah, um processo de faturamento anual e não mensal. [...] conhecer todo, todo o arcabouço das soluções digitais, mas conhecer o ambiente onde isso, onde ele tá querendo entregar isso, onde ele tá querendo atuar. [...] (E7).

[...] a maior desvantagem, eu creio que sejam as novas gerações e que a gente brinca que é a falta de interesse pelo campo. Você se torna cada vez mais digital e menos analógico, menos entendendo, pegando a terra na mão, sentindo, querendo executar menos, planejar mais. [...] Então, nós estamos criando a desvantagem de criar uma geração que ele é totalmente digital, mas com pouca, pouca vivência agronômica [...] (E13).

E7 compreende a necessidade de o profissional da AD conhecer os processos da produção agrícola. Fountas, Pedersen e Blackmore (2005) apontam que o crescimento e o amadurecimento da AD demandam um esforço no desenvolvimento das competências agronômicas e técnicas (eletrônicas) dos profissionais.

E13, por sua vez, manifesta uma preocupação com a perda da conexão das novas gerações de agricultores com o campo, visto que são considerados digitais. O alerta de E13 está em consonância com as pesquisas de Legun, Burch e Klerkx (2022), que afirmam que as competências relacionadas com a aquisição de conhecimentos experienciais por agricultores são essenciais para o bom funcionamento da exploração agrícola.

2 Habilidades necessárias para a AD

As habilidades foram citadas e organizadas por afinidade de significado em seis temas. O tema gestão agrega a maior parte das habilidades nomeadas, isto é, 34% do total de habilidades. O tema tecnologias e ferramentas digitais perfaz 29%, das habilidades reveladas. Comunicação, persuasão e empatia agrupadas num único tema somam 13% das habilidades. Liderança e equipamentos agrícolas são dois temas que apresentam 11% das citações cada uma. Outra habilidade foi citada uma única vez.

2.1 Habilidades de gestão

A gestão envolve uma multiplicidade de habilidades, sendo que os entrevistados relatam a gestão como importante habilidade ao profissional da AD.

[...] o empreendedor, [...] primeiro é saber administrar as falhas, né? Porque o natural é falhar, não é acertar, né? [...] Se o cara quer crescer ele precisa saber gerir isso, né? [...] Então, eu vejo muitos jovens que não tiveram chefe. Então, como eles conseguem ter essa visão de gestão da empresa, né, das dificuldades, das possíveis armadilhas, né? Do que que vai ter ao longo do caminho, aí? (E6).

[...] A própria parte de gestão né? Então, é gestão de tudo. Gestão de tempos, gestão de equipe, gestão de custos, né? (E12).

E6 destaca que algumas dificuldades de gestão dos jovens empreendedores do setor poderiam ser evitadas caso tivessem experiência profissional administrativa anterior em empresas. Para Mcelwee (2008), os agricultores podem ser considerados empresários, uma vez que geram negócios, mas, na prática, não têm necessariamente competências empresariais bem definidas.

E12 aponta a necessidade de o profissional da AD saber gerir. O planejamento, o modelo de negócios e a gestão estratégica são as áreas de competências apontada como as mais importante para os agricultores europeus, segundo o ERASMUS+ project "FIELDS" (Mayor *et al.*, 2022). Para

Michailidis *et al*. (2024), o sucesso da AP está relacionado com a aquisição de novas competências essenciais pelos agricultores, dentre elas, as capacidades técnicas e gerenciais.

2.2 Habilidades de tecnologias e ferramentas digitais

Alguns entrevistados apontam a imprescindibilidade de saber usar as ferramentas digitais, destacando, por exemplo, a necessidade de alfabetização digital.

[...] Plena alfabetização digital, né? [...] E quanto mais profundo ele precisa entrar eh no uso, na cocriação de ferramentas de agricultura digital, eh ou que seja na contratação dessas ferramentas, ele precisa ter noções de programação e de algoritmos (E8).

A alfabetização digital dos trabalhadores agrícolas é apontada por Zabelina, Mirzabalaeva e Sankova (2020) como uma habilidade de alta relevância que traz novas demandas ao sistema educacional e ao modelo de competências dos funcionários, pois exige treinamento e preparação adequados dos profissionais.

A preocupação com a capacidade de análise e interpretação dos dados gerados pelas tecnologias e ferramentas digitais foi explicitada por alguns entrevistados, como o caso das grandes propriedades agrícolas que criam COAs, isto é, Centros de Operações Agrícolas, para realizar o processamento e análise dos dados.

[...] O que fazer com os dados, né? Como ler os dados e como interpretar da melhor forma? Tem muita gente ajudando, mas mas fato é que na massa, isso é uma necessidade sim. [...] (E2).

[...] O grande, ele acabou montando, montando os COAS, né, os Centros de Operações Agrícolas, colocando gente para analisar dados. [...] Com isso também eh tem gente de CRM, tem que ter lá um SAP, um Totvs, eles têm que começar a manejar custo melhor, profissionalizando cada vez mais, né? [...] (E12).

[...] E o grande desafio que ele vai ter, qual que é? É filtrar esse imenso volume de informação, para ele realmente ter eh, eh o que a gente chama da passagem do *big data* para o *right data*, né? Que é ter a informação correta, precisa, no momento certo, para apoiar a tomada de decisão dele. [...] (E14).

As habilidades de análise e interpretação dos dados gerados pelas tecnologias e ferramentas digitais são mencionadas por diversos autores da AD. Para Michailidis *et al*. (2024), as competências necessárias para a AP incluem, dentre outras, a capacidade de interpretação de dados e informações. Mayor *et al*. (2022) ressaltam que as interações frequentes com interfaces digitais e análise de maior quantidade de dados para a tomada de decisão são características da AD.

2.3 Habilidades de comunicação, persuasão e empatia

As habilidades de comunicação, persuasão e empatia foram citadas como fundamentais por alguns entrevistados.

[...] Então é você conseguir compreender que uma pessoa tá num bom dia ou num dia não tão favorável, é isso faz todo todo todo diferencial por um resultado de um trabalho no médio e longo prazo. Então o produtor rural mesmo tem que ter esse, ele sabe como lidar com um funcionário de campo, um funcionário do seu administrativo. Compreender as dificuldades, as pressões, é uma rotina muito pesada. [...] (E14).

[...] eu acho que tem que ter comunicação, né comunicação assertiva, ele tem que saber se comunicar, ele tem que saber se posicionar né? [...]. Ele tem que ter uma habilidade de persuasão também, porque

ele tem que vir com dados aferidos, concretos e tem que ter habilidade de comunicar e persuadir a pessoa para levar, para tomar uma decisão, né? [...] (E15).

Os gestores agrícolas, necessitam também de algumas características pessoais, tais como o desejo de gerir e a capacidade de comunicar com empatia, integridade e honestidade (Hejkrlik; Chaloupkova; Sookolska, 2023). Numa época de comunicação fluida, empregadores, estudantes e professores do setor agroalimentar acreditam que a comunicação é a principal competência necessária para os profissionais do setor (Bodescu *et al*., 2024).

2.4 Habilidades de liderança

As habilidades de liderança são demandadas pela AD segundo os relatos de alguns entrevistados.

[...] hoje que a gente ouve falar muito, desenvolvimento de liderança, né? Porque você precisa às vezes comandar uma equipe, não adianta você só ter pessoas que executam, mas você precisa de pessoas que gerem essa equipe, que gerenciem os trabalhos ali e hoje faltam muitas pessoas com esse perfil. [...] (E3).

[...] os bons gestores, de toda a capacidade técnica que eles têm, a capacidade emocional emotiva de saber lidar com essas com as pessoas mesmo, isso é um diferencial fantástico. [...] (E14).

A liderança é uma habilidade necessária para a AD, segundo E3 e E14. As declarações dos entrevistados demonstram alinhamento com Mayor *et al*. (2022), para quem as competências sociais (incluindo comunicação, trabalho em equipe, negociação etc.) e pessoais (incluindo liderança, flexibilidade, aprendizagem contínua, trabalho sob pressão etc.) são essenciais no contexto da Indústria 4.0. Ravdansuren *et al*. (2021) reiteram a importância da habilidade liderança para a AD, pois associam o desenvolvimento da competência à inovação, à introdução de novas tecnologias na produção agrícola, ao desenvolvimento sustentável e ao aumento de produtividade.

2.5 Habilidades para a operação de equipamentos

A operação de equipamentos da AD é uma necessidade mencionada por alguns entrevistados.

[...] Eu acho que na agricultura digital, acho que ele tem que ter um treinamento para uso dessas ferramentas, né? [...] Essas questões de utilização de drones, o georreferenciamento, operar talvez sensores, diferentes tipos de sensores, né? (E1).

Em harmonia com o relato de E1, Wang *et al*. (2023) afirmam que as tecnologias intensivas em informação da AP, isto é, as tecnologias de diagnóstico, como sensores, imagens de satélite, veículos aéreos não tripulados (VANT) e as tecnologias de taxa variável (VRT), exigem habilidades adicionais e treinamento dos usuários.

3. Atitudes necessárias para a AD

As atitudes distintas foram mencionadas pelos entrevistados como necessárias ao profissional da AD, que aqui estão agrupadas por temas.

3.1 Iniciativa, querer aprender e se atualizar continuamente

Ter iniciativa, querer aprender, evoluir e disponibilidade para aprender o novo são atitudes importantes para alguns entrevistados.

[...] A pessoa tem que ter iniciativa e vontade de querer aprender e evoluir. [...] (E3).

A primeira, a primeira, habilidade, vamos dizer assim, é a disponibilidade de querer, eh, conhecer o novo. Independente do grau de instrução, [...] E se a pessoa, pode não ter estudo, mas se tiver inteligência no sentido de não se colocar barreiras, de observar. [...] (E5).

Querer aprender é uma atitude valiosa no contexto da AD. A AP demanda do agricultor dedicação e tempo para a análise de dados, aprendizagem de novos procedimentos agrícolas, participação em reuniões, cursos e workshops (Fountas; Pedersen; Blackmore, 2005). As competências sociais (incluindo comunicação, trabalho em equipe, negociação etc.) e pessoais (incluindo liderança, flexibilidade, aprendizagem contínua, trabalho sob pressão etc.) são apontadas como essenciais para a Indústria 4.0 (Mayor *et al*., 2022).

3.2 Proatividade

Adotar um comportamento proativo, ou seja, de antecipação das escolhas e ações frente às situações impostas pelo meio, é uma atitude necessária aos profissionais da AD, segundo alguns entrevistados.

Eu acho que atitude é ser proativo. Acho que essa proatividade vai exigir bastante. (E4).

[...] talvez aquele profissional que é, não sei qual vai ser o termo mais adequado, mais aquele que é mais curioso que que vai atrás da informação e aprende sozinho. [...] (E11).

[...] Então, agilidade, proatividade, ele tem que ter, vamos lá, uma série de senso de urgência, espírito de dono, inconformismo construtivo, você tem que ter uma série de *skills*, né? Senso de urgência, espírito de dono, são uma série de habilidades o qual essa pessoa tem que no mínimo desempenhar. [...] (E15).

A relevância da proatividade aos olhos dos entrevistados E4, E11 e E15 para o contexto da AD, é compartilhada por pesquisa conduzida com representantes de nove países da União Europeia, segundo a qual a capacidade de ser resiliente, adaptável e proativo é a quarta competência mais importante para empresas do setor agroalimentar na gestão de equipes (Mayor *et al*., 2022).

3.3 Inteligência emocional

Alguns entrevistados explicam que a inteligência emocional é fundamental para lidar com a complexidade das relações profissionais no contexto da AD.

[...] Nesse núcleo que a gente falou, de pessoas, é, tá tanto a questão da gestão da liderança e da inteligência emocional para um público interligado, né? [...] (E6).

[...] É outra habilidade, inteligência emocional, porque às vezes você tem, você tem situações o qual você é colocado, eh, sob perigo ou sob estresse, né [...] então, você tem que ter a inteligência emocional para saber lidar com isso. [...] (E15).

Identificar e lidar com as emoções e sentimentos pessoais e de outros indivíduos é importante para o profissional no ecossistema da AD, segundo os entrevistados E6 e E15. A inteligência emocional melhora a integração de recursos dos empreendedores, amplia as suas capacidades e melhora o seu desempenho geral. Os agricultores-empreendedores mais agressivos, socialmente capazes, inovadores e emocionalmente estáveis, são mais inclinados a ter sucesso (Zhang *et al*., 2022).

CONCLUSÃO

Este artigo teve como objetivo conhecer e comparar as competências (conhecimentos, habilidades e atitudes) necessárias para o profissional da AD, encontradas na produção científica (identificadas por meio de revisão de literatura), e a opinião de representantes dos *stakeholder*s da AD.

A comparação identificou um alinhamento entre as competências apresentadas pelos entrevistados e a literatura, ou seja, as competências mencionadas livremente pelos entrevistados na entrevista encontram respaldo na produção científica: tecnologias e ferramentas digitais, agronomia, gestão, liderança, operação de equipamentos, e comunicação. As atitudes para a AD citadas pelos profissionais também são encontradas nas pesquisas analisadas, que são: iniciativa, querer aprender e se atualizar continuamente, proatividade e inteligência emocional.

Outro fator que vale ser mencionado é que, muito embora nenhuma função tenha sido citada pelos autores em nenhuma das questões da entrevista, inclusive na pergunta que é objeto do presente trabalho que questiona sobre as competências necessárias para o profissional que atua na AD, a grande maioria dos entrevistados, naturalmente, se referiram às competências necessárias ao agricultor. Os entrevistados E2, E6 e E8 e E12, por exemplo, trouxeram em suas respostas dados sobre competências de outros stakeholders da AD.

A revisão de literatura que destaca as pesquisas científicas relacionadas ao tema, competências para o profissional da AD, independentemente da função, é uma das contribuições deste trabalho.

A opinião dos entrevistados oriundos de diferentes *stakeholders* da AD brasileira é também outra contribuição, pois os profissionais adicionam ao estudo uma visão prática e experiencial das competências necessárias para a atuação do profissional nas atividades relacionadas à AD, e apoiam a construção de uma visão multidisciplinar e holística sobre o tema.

Pesquisas futuras com diferentes *stakeholders* da AD podem adicionar à reflexão aqui realizada dados complementares sobre os desafios para a implantação da AD, competências necessárias aos profissionais e soluções. Outras competências mencionadas na literatura, tais como sustentabilidade e bioeconomia, além de outras, podem ser referendadas por outros profissionais e *stakeholders* da área.

AGRADECIMENTOS

Esta pesquisa é financiada pelo Plano de Incentivo à Pesquisa - PIPEq da Pontifícia Universidade Católica de São Paulo (PUC-SP), pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq e pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (Capes).

REFERÊNCIAS

AYRE, Margaret; Mc COLLUM, Vivienne; WATERS, Warwick; SAMSON, Peter; CURRO, Anthony; NETTLE, Ruth; PASCHEN, Jana-Axinja; KING, Barbara; REICHELT, Nicole. Supporting and practising digital innovation with advisers in smart farming. **NJAS-Wageningen Journal of Life Sciences**, v. 90, p. 100302, 2019.

BODESCU, Dan *et al*. Relevant Skills for Employment and Entrepreneurship in the Agri-Food Sector. Sustainability, v. 16, n. 2, p. 787, 2024.

BRANDÃO, Hugo Pena. Mapeamento de competências: métodos, técnicas e aplicações em gestão de pessoas. **São Paulo: Atlas**, 2023.

CARBONE, Pedro Paulo; BRANDÃO, Hugo Pena; LEITE, João Batista Diniz. Gestão por competências e gestão do conhecimento. In: Gestão por competências e gestão do conhecimento. 2006. p. 176-176.

DA SILVEIRA, Franco *et al*. Farmers' perception of barriers that difficult the implementation of agriculture 4.0. Agricultural Systems, v. 208, p. 103656, 2023.

DUTRA, Joel Souza. Competências: conceitos, instrumentos e experiências. 2017.

FAO. The future of food and agriculture -drivers and triggers for transformation. The Future of Food and Agriculture, n. 3, 2022.

FLEURY, Afonso; FLEURY, Maria Tereza Leme. Estratégias empresariais e formação de competências: um quebra-cabeça caleidoscópio da indústria brasileira. 2001.

FOUNTAS, Spyros; PEDERSEN, Søren Marcus; BLACKMORE, Simon. ICT in Precision Agriculture-diffusion of technology. ICT in agriculture: perspective of technological innovation, E. Gelb and A. Offer (eds), http://departments. agri. huji. ac. il/economics/gelb-main. html, 2005.

HEJKRLIK, Jiri; CHALOUPKOVA, Petra; SOKOLSKA, Tetyana. The role of transformational leadership and leaders' skills for new agricultural cooperatives in post?soviet countries. **Annals of Public and Cooperative Economics**, v. 94, n. 1, p. 109-129, 2023.

KLERKX, Laurens; JAKKU, Emma; LABARTHE, Pierre. A review of social science on digital agriculture, smart farming and agriculture 4.0: New contributions and a future research agenda. NJAS-Wageningen journal of life sciences, v. 90, p. 100315, 2019.

LEGUN, Katharine; BURCH, Karly Ann; KLERKX, Laurens. Can a robot be an expert? The social meaning of skill and its expression through the prospect of autonomous AgTech. Agriculture and Human Values, v. 40, n. 2, p. 501-517, 2023.

MASSRUHÁ, Silvia M. F. S.; LEITE, Maria A. L.; OLIVEIRA, Stanley D. M.; MEIRA, Carlos A. A.; LUCHIARI JUNIOR, Ariovaldo; BOLFE, Edson L. Agricultura digital: pesquisa, desenvolvimento e inovação nas cadeias produtivas. 2020.

MATTAR, João; RAMOS, Daniela Karine. Metodologia da pesquisa em educação: abordagens qualitativas, quantitativas e mistas. Grupo Almedina, 2021.

MAYOR, Luis *et al*. Skill Needs for Sustainable Agri-Food and Forestry Sectors (I): Assessment through European and National Focus Groups. Sustainability, v. 14, n. 15, p. 9607, 2022.

MCELWEE, Gerard. A taxonomy of entrepreneurial farmers. International journal of entrepreneurship and small business, v. 6, n. 3, p. 465-478, 2008.

MICHAILIDIS, Anastasios *et al*. A First View on the Competencies and Training Needs of Farmers Working with and Researchers Working on Precision Agriculture Technologies. Agriculture, v. 14, n. 1, p. 99, 2024.

OKOLI, Chitu. Guia Para Realizar uma Revisão Sistemática da Literatura. Tradução David Wesley Amado Duarte, João Mattar. EAD EM FOCO, v. 9, n. 1, 2019.

RAVDANSUREN, Chantsaldulam *et al*. Leadership Skills Impact On Leader's Performance: A Case Of Mongolian Agricultural Industry. European Proceedings of Social and Behavioural Sciences.

ROSSI JUNIOR, José Luiz; DOYLE, Morgan. Desafios de desenvolvimento do país: rota para um crescimento sustentável e inclusivo. Banco Interamericano de Desenvolvimento: Brasil, jun. 2023. http://dx.doi.org/10.18235/0004944.

RUBIN, Herbert J.; RUBIN, Irene S. Qualitative interviewing: The art of hearing data. Sage, 2011.

SALDAÑA, Johnny. The coding manual for qualitative researchers. Sage, 2013.

WANG, Tong *et al*. Understanding farmer views of precision agriculture profitability in the US Midwest. **Ecological Economics**, v. 213, p. 107950, 2023.

WEERSINK, Alfons; FRASER, Evan; PANNELL, Dave; DUNCAN, Emily; ROTZ, Sarah. Opportunities and challenges for big data in agricultural and environmental analysis. Annual Review of Resource Economics, v. 10, p. 19-37, 2018.

ZABELINA, Olga V.; MIRZABALAEVA, Farida I.; SANKOVA, Larisa V. Readiness of agricultural workers to develop new competencies and change the employment model in the conditions of digitalization. In: E3S Web of Conferences. EDP Sciences, 2020. p. 06003.

ZHANG, Shasha *et al*. Non-cognitive skills and farmers' entrepreneurial performance: evidence from Chinese family panel studies. **Agriculture**, v. 12, n. 8, p. 1143, 2022.