


# ANAIS



**ConBAP**  
CONGRESSO BRASILEIRO DE  
AGRICULTURA DE PRECISÃO **2022**

**09/08 A**  
**11/08/2022**  
**EXPO D. PEDRO | CAMPINAS - SP**

# ISBN E DADOS DE PUBLICAÇÃO

## Anais do Congresso Brasileiro de Agricultura de Precisão 2022

09 a 11 de Agosto de 2022, Campinas -SP

### Edição Técnica

Leandro Maria Gimenez (Esalq/USP) & Christian Bredemeier (UFRGS)

*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 SisGen.*

Copyright © 2022 – 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 organização do evento e da Associação Brasileira de Agricultura de Precisão e Digital (AsBraAP).



# APRESENTAÇÃO

O ConBAP é um evento bienal que reúne cerca de 800 participantes entre pesquisadores, profissionais de assistência técnica e extensão, professores, estudantes, empresas e produtores rurais, usuários das diferentes técnicas envolvidas no amplo leque da Agricultura de Precisão (AP). A Edição 2022 do ConBAP foi realizada em Campinas-SP na Expo D. Pedro – Campinas de 09 a 11 de agosto de 2022. O evento foi promovido pela Associação Brasileira de Agricultura de Precisão e Digital (AsBraAP) e teve como tema "Agricultura de precisão na era digital".

A Agricultura de Precisão é um conjunto de ações de gestão do sistema de produção que leva em consideração a variabilidade espacial das lavouras e incorpora inovações tecnológicas que permitem o seu tratamento num grau de detalhamento mais elevado que a prática usual, sendo, portanto, mais acurado.

O ConBAP contempla palestras, plenárias, painéis setoriais, apresentação de trabalhos científicos, espaço para empresas exporem seus produtos e serviços, além de um espaço para apresentações dos patrocinadores e expositores ("Sala do Mercado de AP"). Tudo isso cria o cenário adequado para relacionamento com os profissionais e usuários que trabalham com Agricultura de Precisão no Brasil e no mundo.

# COMISSÃO ORGANIZADORA E CIENTÍFICA

## **Leandro Maria Gimenez**

Universidade de São Paulo, Escola Superior de Agricultura Luiz de Queiroz (Esalq/USP)

## **Christian Bredemeier**

Universidade Federal do Rio Grande do Sul (UFRGS)

## **Domingos Sárvio Magalhães Valente**

Universidade Federal de Viçosa (UFV)

## **José Paulo Molin**

Universidade de São Paulo, Escola Superior de Agricultura Luiz de Queiroz (Esalq/USP)

## **Samuel de Assis Silva**

Universidade Federal do Espírito Santo (UFES)

## **Lucas Rios do Amaral**

Universidade Estadual de Campinas (Unicamp)

## **Lúcio De Paula Amaral**

Universidade Federal de Santa Maria (UFSM)

## **Rodrigo Sinaidi Zandonadi**

Universidade Federal de Mato Grosso (UFMT)

## **Revisores *ad hoc***

Alessandro Samuel-Rosa

André Freitas Colaço

André Luis Vian

Angel Pontin Garcia

Antônio Luis Santi

Celia Regina Grego

Christian Bredemeier

Claudio Leones Bazzi

Fabio Henrique Rojo Baio

Gabriel Araújo E Silva Ferraz

Gleyce Kelly Dantas Araujo Figueiredo

Gustavo Di Chiacchio Faulin

Henrique Oldoni

Juliana Aparecida Fracarolli

Leandro Maria Gimenez

Lucas De Paula Corrêdo

Luciano Gebler

Luis Henrique Bassoi

Marisa Silveira Almeida Renaud Faulin

Matheus Gabriel Acorsi

Miguel Angel Uribe Opazo

Murilo Mesquita Baesso

Peterson Ricardo Fiorio

Rafael Vieira De Sousa

Renato Maravalhas De Carvalho Barros

Ronaldo Pereira De Oliveira

Ronilson De Souza Santos

Rouverson Pereira Da Silva

Rubens Lamparelli

Samuel De Assis Silva

Sarvio Valente

Taciara Zborowski Horst

Thiago Libório Romanelli

Tiago Rodrigues Tavares



# PROGRAMAÇÃO

Horário	Dia 09/08/2022
13:00 - 15:15	<a href="#">Plenária 1: TEMA - Presente e Futuro da AP</a>
13:00 - 13:15	<b>Solenidade de abertura</b>
13:15 - 14:00	<b>Palestra 1 - 25 anos de AP no Brasil: análise e perspectivas</b> <i>Palestrante: Dr. José Paulo Molin - ESALQ-USP</i>
14:00 - 14:45	<b>Palestra 2 - A AP no Mundo: análise e perspectivas</b> <i>Palestrante: Prof. James Taylor - Research Director, INRAE, Montpellier</i>
14:45 - 15:15	<b>Perguntas e Debate</b>
15:15 - 16:00	Coffee break e visita aos estandes - Lançamento do livro Agricultura Digital
16:00 - 18:00	<a href="#">Plenária 2: TEMA - AP como ferramenta para sustentabilidade</a>
16:00 - 16:45	<b>Palestra 3 - Desafios e oportunidades atuais: ESG, mercado de carbono, rastreabilidade, uso consciente da terra</b> <i>Palestrante: Luiz Carlos Corrêa Carvalho - ABAG</i>
16:45 - 17:30	<b>Palestra 4 - Quais os limites para as recomendações regionais? Uma perspectiva sobre o uso intensivo de dados gerados na fazenda</b> <i>Palestrante: Dr. David S Bullock - University of Illinois, Agricultural &amp; Consumer Economics</i>
17:30 - 18:00	<b>Perguntas e Debate</b>
18:00	Coquetel

Horário	Dia 10/08/2022
08:40 - 10:00	<a href="#">Plenária 1: TEMA - Aplicações e Oportunidades</a>
08:40 - 09:00	<b>Palestra 5 - Qualidade do Solo e o papel do carbono</b> <i>Palestrante: Dr. Maurício Cherubin - ESALQ-USP</i>
09:00 - 09:20	<b>Palestra 6 - Manejo da Irrigação</b> <i>Palestrante: Dr. Luís Henrique Basso - Embrapa Instrumentação</i>
09:20 - 09:40	<b>Palestra 7 - AP em pastagens extensivas</b> <i>Palestrante: Dr. Alberto Carlos de Campos Bernardi - Embrapa Pecuária Sudeste</i>

Horário	Dia 10/08/2022
09:40 - 10:00	<b>Perguntas e Debate</b>
09:00 - 17:15	<a href="#">Sala de mercado</a>
09:00 - 09:15	<b>CLIMATE: O próximo passo de produtividade é digital.</b> <i>Renan Arantes</i>
09:30 - 09:45	<b>INCERES: O planejamento e a jornada da fertilidade do solo: como ajudar o agricultor a obter resultados.</b> <i>Leonardo Menegatti</i>
09:45 - 10:00	<b>STARA : Tecnologias que garantem altas produtividades</b> <i>Palestrante: Thomas Liska</i>
10:30 - 10:45	<b>JACTO: Aplicação de agricultura 5.0 em campo</b> <i>Palestrante: Cristiano Okada Pontelli</i>
10:45 - 11:00	<b>IBRA: A Precisão das Zonas de Manejo - Atributos imutáveis do solo</b> <i>Patrick Garcia - IBRA MegaLab</i>
11:00 - 11:15	<b>GEOAGRI: Tecnologias Inovadoras para o Controle de Plantas Daninhas Resistentes.</b> <i>Leandro Santos</i>
11:15 - 11:30	<b>TOPCON: Integração de conhecimentos: como tecnologias, dados e sustentabilidade se correlacionam.</b> <i>Bruna Passalacqua</i>
11:30 - 11:45	<b>YARA: Programa Nutrir o Brasil - Aplicação Nitrogenada em taxa variável</b> <i>Mateus Pereira</i>
11:45 - 12:00	<b>HEXAGON: Soluções digitais para agricultura</b> <i>Márcio Blau - Gerente de Vendas América Latina da divisão de Agricultura da Hexagon</i>
15:30 - 15:45	<b>AGGATEWAY</b>
15:45 - 16:00	<b>BIOME4ALL: Conhecendo a microbiota do solo e seus benefícios a favor da sustentabilidade, eficiência e produtividade no agronegócio.</b> <i>Leonardo Gomes</i>
16:00 - 16:15	<b>JOHN DEERE: Tenha a sua Fazenda Digital.</b> <i>Isabela Cocatto - Especialista de Marketing de Produto Soluções Digitais</i>
16:15 - 16:30	<b>RIBERSOLO: O futuro das análises de solo: controles de qualidade e sensoriamento</b> <i>Palestrante: Victor Monseff de Almeida Campos</i>
16:30 - 16:45	<b>New Holland: É Natural ser Digital: o ecossistema das máquinas conectadas.</b> <i>Sayuri Motoshima</i>

Horário	Dia 10/08/2022
16:45 - 17:00	<b>EMBRAPA: AgroAPI - plataforma digital da Embrapa para potencializar novas soluções em Agricultura de Precisão.</b> <i>Luciana Alvim Santos Romani</i>
17:00 - 17:15	<b>TECGRAF: Considerações acerca do Fluxo de Trabalho para o Planejamento de Trajetórias no Campo.</b> <i>João Camelini</i>
10:00 - 10:30	Coffee break e visita aos estandes
10:30 - 12:15	Apresentações orais de Trabalhos Científicos - Sessões simultâneas em 3 salas
13:30 - 15:00	<a href="#">Plenária 2: Tema - Transferência e Adoção de Tecnologias</a>
13:30 - 13:40	<b>Abertura</b>
13:40 - 14:00	<b>Palestra 8 - Ensino</b> <i>Palestrante: Dr. Antônio Luis Santi - Universidade Federal de Santa Maria</i>
14:00 - 14:20	<b>Palestra 9 - Extensão</b> <i>Palestrante: Dr. Geomar Corassa - CCGL</i>
14:20 - 14:40	<b>Palestra 10 - Treinamento</b> <i>Palestrante: Mateus Moraes Tavares - Senar</i>
14:40 - 15:00	<b>Perguntas e Debate</b>
15:00 - 15:30	Coffee break e visita aos estandes
15:30 - 16:30	Apresentação de trabalhos Científicos em sessão de pôsteres
16:30 - 18:00	<a href="#">Plenária 3: Tema - Automação e Suporte à Tomada de Decisão</a>
16:30 - 16:40	<b>Abertura</b>
16:40 - 17:00	<b>Palestra 11 - Uso de ARPs</b> <i>Palestrante: Prof. Ulisses Antuniassi - UNESP</i>
17:00 - 17:20	<b>Palestra 12 - Automação total - Robótica</b> <i>Palestrante: Dr. Antônio Leite - Noruega Norwegian University of Life Sciences NMBU</i>
17:20 - 17:40	<b>Palestra 13 - Integração da Modelagem Agrometeorológica à AP</b> <i>Palestrante: Dr. Rodrigo Tsukahara - Fundação ABC</i>
17:40 - 18:00	<b>Perguntas e Debate</b>
18:30	Reunião associados AsBraAP

Horário	Dia 11/08/2022
08:30 - 10:00	<a href="#">Plenária 1: TEMA - Uso de ferramentas para controle e manejo</a>
08:30 - 09:15	<b>Palestra 14 - Demandas e experiências com planejamento de tráfego e controle de amassamento</b> <i>Palestrante: Rodrigo Zandonadi - UFMT</i>
09:15 - 09:45	<b>Palestra 15: Soluções de precisão no uso eficiente de fertilizantes e insumos</b> <i>Ronaldo Oliveira (Embrapa Solos)</i>
09:45 - 10:00	<b>Perguntas e Debate</b>
10:00 - 10:30	Coffee break e visita aos estandes
10:30 - 11:50	<a href="#">Plenária 2: TEMA - Transformação Digital</a>
10:30 - 11:00	<b>Palestra 16 - Dados e Big Data: fontes e estratégias de análise</b> <i>Palestrante: Dr. Rodrigo Trevisan - Vayda</i>
11:00 - 11:30	<b>Palestra 17 - Integração da cadeia: o exemplo da certificação do algodão com AP</b> <i>Palestrante: Fábio Antônio Carneiro - Abrapa (Associação Brasileira dos Produtores de Algodão)</i>
11:30 - 11:50	<b>Perguntas e Debate</b>



# INFORMAÇÕES

O ConBAP 2022 contou com um número recorde de 664 participantes de todas as regiões do país e do exterior. O evento foi realizado na cidade de Campinas (SP), no Expo D. Pedro, de 9 a 11 de agosto. Durante o evento, foram apresentados 68 trabalhos científicos e apresentados 17 palestras/painéis, além da sala de mercado, somando 17 horas de conteúdo. O Congresso teve o apoio de 33 expositores/patrocinadores.



# SUMÁRIO

## Sumário

<b>1. Agronomia/Manejo.....</b>	<b>12</b>
<b>APLICAÇÃO DA METODOLOGIA <i>SPECKLE</i> NA INVESTIGAÇÃO DA CLASSE TEXTURAL DO SOLO.....</b>	<b>13</b>
Gustavo Di Chiacchio Faulin; Rafael Alves da Silva; Gildemberg Amorim Leal Junior; Rita de Cássia Mendonça Sales Contini; Sidney Leal da Silva.....	13
<b>FATORES QUE IMPACTAM A RESPOSTA DA CANA-DE-AÇÚCAR AO NITROGÊNIO PARA FINS DE MANEJO LOCALIZADO.....</b>	<b>18</b>
Guilherme Martineli Sanches; Rafael Otto; Etori Veronezi; Mariana Rodrigues.....	18
<b>A VARIABILIDADE ESPACIAL DA VAZÃO DE GOTEJADORES AFETA A PERFORMANCE DA IRRIGAÇÃO LOCALIZADA PARA O CULTIVO DE VIDEIRAS VINÍFERAS .....</b>	<b>27</b>
Larissa Godarelli Farinassi; Bruno Ricardo Silva Costa; Luis Henrique Bassoi.....	27
<b>CLASSIFICAÇÃO DE PRESENÇA-AUSÊNCIA DE PLANTAS DANINHAS DE FOLHA LARGA EM PASTAGEM POR SENSORIAMENTO REMOTO .....</b>	<b>34</b>
Cenneya Lopes Martins; Agda Loureiro Gonçalves Oliveira; Joaquim Pedro de Lima; Henrique Oldoni; Lucas Rios do Amaral.....	34
<b>SISTEMA PARA O MONITORAMENTO DA FERRUGEM ASIÁTICA DA SOJA A PARTIR DE COLETORES DE ESPOROS E MAPAS DE FAVORABILIDADE AMBIENTAL.....</b>	<b>43</b>
Ivan Carlos Maldaner; Luciano Pes; Luiz Felipe Silveira Pavão; Veronica Fuzer Guarienti; Rafaela da Silva Rodrigues .....	43
<b>INTERAÇÃO ENTRE A INFESTAÇÃO DE PHOMA E INDICADORES DE SOLO E PLANTA EM LAVOURA DE CAFÉ NO PLANALTO DE VITÓRIA DA CONQUISTA-BA .....</b>	<b>48</b>
Derlei Dias Melo; Odair Lacerda Lemos; Ingrid Thalia Prado de Castro; Leandro Dias da Silva; Juliana Santos Abrantes Silva .....	48
<b>PERÍODO ÓTIMO DE COLHEITA DE MANDIOCA DEFINIDO A PARTIR DE INFORMAÇÕES DE SENSOR EMBARCADO EM VANT .....</b>	<b>56</b>
RONILSON DE SOUZA SANTOS; BRENO DA SILVA SANTOS; RADMIR DA SILVA ARAÚJO; DJAIR ALVES MOREIRA; GIOVANNI STEFANO GOMES DE SOUSA.....	56
<b>ALTERAÇÃO DA DENSIDADE DO SOLO POR OPERAÇÕES AGRÍCOLAS MECANIZADAS: INTERAÇÃO ENTRE AMBIENTE E EQUIPAMENTO .....</b>	<b>65</b>
Vinícius Grillo; Alessandro Alvarenga Pereira da Silva ; Matheus Gabriel Acorsi; Leandro Maria Gimenez.....	65
<b>MAPAS DE NDVI PARA DEFINIÇÃO DE UNIDADES DE MANEJO DIFERENCIADAS PARA A VITIVINICULTURA .....</b>	<b>77</b>
André Luis Vian; JÚLIA FACCIN FAÉ; LUÍS FELIPE GERLACH; ALEXANDRE ALAN CASSINELLI; GABRIEL RIEDER MARSON.....	77
<b>ESPECTROSCOPIA DE INFRAVERMELHO PRÓXIMO (NIR) PARA ESTIMATIVA DO TEOR DE NITROGÊNIO EM TECIDO VEGETAL DE MILHO .....</b>	<b>82</b>
André Luis Vian; ELISA MARIA BERFT; VICTOR FAGUNDES ABIANNA; DIEGO LIMA LUCCHESI; GABRIELA NAIBO .....	82
<b>MANEJO DE GRAMÍNEA UTILIZANDO IMAGEM DE SENSOR ÓPTICO EMBARCADO EM VEÍCULO AÉREO NÃO TRIPULADO (VANT) .....</b>	<b>87</b>
RONILSON DE SOUZA SANTOS; JOIRO JORGE VILAR SOUZA ; DÉBORA CAROLINE ARAÚJO DE JESUS ; BRENO DA SILVA SANTOS; RADMIR ARAÚJO DE SOUZA.....	87
<b>2. Aplicação Localizada.....</b>	<b>93</b>
<b>UM ESTUDO DE CASO EM CITRUS: 6 ANOS DE ADUBAÇÃO EM DOSE FIXA E VARIADA .....</b>	<b>94</b>
Luis Gustavo Mendes; Marcelo Chan Fu Wei; José Paulo Molin.....	94

<b>3. Economia.....</b>	<b>100</b>
AGRICULTURA DE PRECISÃO NO SETOR SUCROALCOOLEIRO DO ESTADO DE SÃO PAULO : ANÁLISE PRODUTIVA, ECONÔMICA E AMBIENTAL.....	101
<i>João Vitor Costa Mazzi; Adriana Estela Sanjuan Montebello; Jeronimo Alves dos Santos.....</i>	<i>101</i>
<b>4. Eletrônica e transformação digital.....</b>	<b>109</b>
CONTROLADOR DE BAIXO CUSTO PARA SEMEADURA À TAXA VARIADA .....	110
<i>André Luiz de Freitas Coelho ; Giovani Prates Bisso Drambroz; Daniel Marçal de Queiroz; Domingos Sárvio Magalhães Valente; Francisco de Assis de Carvalho Pinto .....</i>	<i>110</i>
ANÁLISE DE UMA ARQUITETURA EM NUVEM DA AWS PARA TELEMETRIA EM MÁQUINAS AGRÍCOLAS.....	118
<i>SANDRO MOTTER; ALEXANDRE LAZARETTI ZANATTA; GUILHERME SILVA DE OLIVEIRA; ANDREI BECKER PACHECO; EDINEI FIORESE .....</i>	<i>118</i>
SISTEMA EMBARCADO DE COLETA DE DADOS PARA GERAÇÃO DE MAPAS DE PRODUTIVIDADE EM FRUTICULTURA.....	128
<i>Ricardo Sobjak; Paula Leticia Souza de Moura; Eduin Nasael Torres Avila; Luciano Gebler; Claudio Leones Bazzi.....</i>	<i>128</i>
USO DE MOTORES ELÉTRICOS EM SEMEADORAS E GANHO DE PRODUTIVIDADE NA CULTURA DA SOJA.....	134
<i>Airton Polon.....</i>	<i>134</i>
<b>5. Sensoriamento e amostragem .....</b>	<b>143</b>
DIAGNÓSTICO DA FERTILIDADE DO SOLO VIA XRF: PRECISAMOS CONSIDERAR A PROFUNDIDADE E A ÁREA DA AMOSTRA NA MODELAGEM PREDITIVA? .....	144
<i>Tiago Rodrigues Tavares; Carlos Roberto Pinheiro Junior; Elton Eduardo Novais Alves; Rachel Ferraz de Camargo; Hudson Wallace Pereira de Carvalho .....</i>	<i>144</i>
GERAÇÃO DE ZONAS DE MANEJO EM POMARES DE MACIEIRAS COM BASE EM NDVI E PRODUTIVIDADE: UMA ANÁLISE EXPLORATÓRIA .....	153
<i>Luciano Gebler; Renata Bulling Magro; Andrea de Rossi; Eduardo Antonio Speranza; Marcio da Silva Santos .....</i>	<i>153</i>
APLICAÇÃO DE TEXTURAS EM IMAGENS DIGITAIS COLETADAS POR RPA PARA ESTIMATIVA DE BIOMASSA DE PASTAGEM .....	164
<i>Rodrigo Greggio de Freitas; Gleyce Kelly Dantas Figueiredo; Lucas Rios do Amaral.....</i>	<i>164</i>
PREDIÇÃO DE ATRIBUTOS DE FERTILIDADE DO SOLO USANDO SENSOR XRF: COMPARAÇÃO DE MODELOS LINEARES SIMPLES, MÚLTIPLOS E PLSR .....	174
<i>Rachel Ferraz de Camargo; Gabriel Villela Bedum; Tiago Rodrigues Tavares; Murilo Oliveira Cardoso; Hudson Wallace Pereira de Carvalho.....</i>	<i>174</i>
DESEMPENHO DE SENSOR XRF PARA PREDIÇÃO DE TEXTURA, PH, ALUMÍNIO E MATÉRIA ORGÂNICA EM SOLOS TROPICAIS DE SÃO PAULO .....	183
<i>Marcos Mantelli Ragagnin; Gabriel Gava; Inácio Duarte Vieira; Carlos Roberto Pinheiro Júnior; Tiago Rodrigues Tavares .....</i>	<i>183</i>
DESEMPENHO DE SENSOR XRF PARA PREDIÇÃO DE MACRONUTRIENTES, CAPACIDADE DE TROCA DE CÁTIONS E SATURAÇÃO DE BASES EM SOLOS TROPICAIS .....	192
<i>Gabriel Toledo Marques; Tiago Rodrigues Tavares; Thainara Rabelo da Silva ; Carlos Roberto Pinheiro Junior; José Paulo Molin.....</i>	<i>192</i>
DIFERENTES MÉTODOS DE SENSORIAMENTO PROXIMAL DO DOSSEL DE VIDEIRAS PROMOVEM DIVERGÊNCIAS NO MAPEAMENTO DE ÍNDICES DE VEGETAÇÃO .....	200
<i>Larissa Godarelli Farinassi; Henrique Oldoni; Luis Henrique Bassoi; Bruno Ricardo Silva Costa.....</i>	<i>200</i>
VARIABILIDADE ESPACIAL DA CONDUTIVIDADE ELÉTRICA APARENTE AO LONGO DO PERFIL DO SOLO DE VINHEDOS COMERCIAIS .....	208
<i>Bruno Ricardo Silva Costa; Larissa Godarelli Farinassi; Ladislau Marcelino Rabello; Carlos Manoel Pedro Vaz; Luís Henrique Bassoi.....</i>	<i>208</i>

SISTEMA EMBARCADO PARA PREDIÇÃO DE CALCIO E MAGNÉSIO EM AMOSTRAS DE SOLO .....	213
<i>Thiago Furtado de Oliveira; Domingos Sarvio Magalhães Valente.....</i>	<i>213</i>
APLICAÇÃO DO ÍNDICE DE VEGETAÇÃO PARA CORRELAÇÃO DO DESENVOLVIMENTO REPRODUTIVO DO AÇAIZEIRO .....	221
<i>JAMILE DO NASCIMENTO SANTOS; IZADORA DE CASSIA MESQUITA DA CUNHA; ODAILSON RODRIGUES DO NASCIMENTO; YARA KARINE DE LIMA SILVA; FABIO JÚNIOR DE OLIVEIRA .....</i>	<i>221</i>
SENSORIAMENTO REMOTO AÉREO E PROXIMAL PARA A PREDIÇÃO DE PRODUTIVIDADE DE MILHO FORRAGEIRO .....	229
<i>Jussara Oliveira Gervasio; Gabriela Maria Amaral Vallim Costa; Samuel de Assis Silva .....</i>	<i>229</i>
AERONAVE REMOTAMENTE PILOTADA PARA O PLANEJAMENTO DE PLANTIO DE CAFÉ .....	238
<i>Lucas Santos Santana; Gabriel Araújo e Silva Ferraz; Nicole Lopes Bento; Sabrina Aparecida Teodoro ; Rafael de Oliveira Faria.....</i>	<i>238</i>
DIFERENTES SENSORES EMBARCADOS EM VANT PARA PREDIÇÃO DA BIOMASSA DE PASTAGEM .....	244
<i>Gabriela Maria Amaral Vallim Costa; Jussara Oliveira Gervasio; Samuel de Assis Silva .....</i>	<i>244</i>
CORRELAÇÃO ENTRE IAF E NDVI DE CULTIVARES CAFEIRAS RECÉM TRANSPLANTADAS COM IMAGENS AÉREAS OBTIDAS POR AERONAVE REMOTAMENTE PILOTADA .....	256
<i>Lucas Santos Santana; Sabrina Aparecida Teodoro; Nicole Lopes Bento; Gabriel Araújo e Silva Ferraz; Pedro Henrique de Oliveira Estima.....</i>	<i>256</i>
VARIABILIDADE ESPACIAL E TEMPORAL ENTRE TALHÕES DE <i>COFFEA ARABICA</i> .....	261
<i>Eudocio Rafael Otavio da Silva; Thiago Lima da Silva; Ricardo Augusto de Souza; Marcelo Chan Fu Wei; José Paulo Molin.....</i>	<i>261</i>
USO DE IMAGENS MULTIESPECTRAIS EM CULTIVAR DE CÍTRUS DA VARIEDADE PÊRA (CITRUS SINENSIS L. OSBECK) CULTIVADAS COM APLICAÇÃO DE GESSO AGRÍCOLA .....	270
<i>ODAILSON RODRIGUES DO NASCIMENTO; JAMILE DO NASCIMENTO SANTOS; IZADORA DE CASSIA MESQUITA DA CUNHA; FLAVIO HENRIQUE SANTOS RODRIGUES; FABIO JÚNIOR DE OLIVEIRA .....</i>	<i>270</i>
PREDIÇÃO DA PRODUTIVIDADE DE SOJA VIA ÍNDICES DE VEGETAÇÃO .....	278
<i>Natasha Costa Penatti; Aline Edlaine de Medeiros; ROSEANNE LARISSA FABENI ; JULIANO DONINI DA SILVA .....</i>	<i>278</i>
CONFIGURAÇÕES AMOSTRAIS DIRIGIDAS POR UNIDADES DE GESTÃO DIFERENCIADA PARA FERTILIDADE DO SOLO .....	288
<i>Mateus Borges Naciben; Henrique Oldoni; Thiago Luís Brasco; Maiara Pusch; Lucas Rios do Amaral.....</i>	<i>288</i>
ÍNDICE DE REFLECTÂNCIA DE SENESCÊNCIA DE PLANTAS EM VIDEIRAS .....	294
<i>Lúcio de Paula Amaral; Regiane Aparecida Ferreira; Luiz Felipe Diaz de Carvalho; Aline de Oliveira Fogaça; Luciano Gebler.....</i>	<i>294</i>
DESEMPENHO DE SENSOR XRF PARA PREDIÇÃO DE MICRONUTRIENTES E SULFATO EM SOLOS TROPICAIS DE SÃO PAULO .....	300
<i>Mateus Silva Gelain; Larissa Cardoso; Carlos Roberto Pinheiro Junior; Tiago Rodrigues Tavares; Jose Paulo Molin.....</i>	<i>300</i>
SENSORES DE DISTÂNCIA PARA MEDIDAS DE ALTURA DO DOSSEL FORRAGEIRO.....	306
<i>Orlando Daniel Masnello; José Paulo Molin .....</i>	<i>306</i>
ESPECTROSCOPIA NIR APLICADA AO MAPEAMENTO DA VARIABILIDADE ESPACIAL DA QUALIDADE DE CANA-DE-AÇÚCAR .....	310
<i>Lucas de Paula Corrêdo; José Paulo Molin.....</i>	<i>310</i>
DESENVOLVIMENTO DE UM SENSOR ÓPTICO PARA MENSURAÇÃO DE ATRIBUTOS FÍSICOS DE TOMATES A PARTIR DE IMAGENS DIGITAIS .....	322
<i>João Célio Luna de Carvalho; Anderson Gomide Costa.....</i>	<i>322</i>
ANÁLISE TEMPORAL DE DADOS DE NDVI PARA DEFINIÇÃO DE ZONAS DE MANEJO .....	328
<i>Ricardo Sobjak; Jackson Sieben; Glaucio Jose Gomes; Kelyn Schenatto; Claudio Leones Bazzi .....</i>	<i>328</i>



DINÂMICA ESPAÇO-TEMPORAL DO ÍNDICE DE ÁREA FOLIAR DE CAFEEIROS ESQUELETADOS ESTIMADO POR SENSORIAMENTO REMOTO AÉREO.....	337
<i>Samuel de Assis Silva; Marco Henrique Souza de Sá; Levi Fraga Pajehú; Julião Soares de Souza Lima</i> .....	337
SENSORIAMENTO REMOTO PARA A ESTIMATIVA DE PRODUTIVIDADE DE CAFÉ ARÁBICA EM LAVOURA MICROTERRACEADA .....	347
<i>Jussara Oliveira Gervasio; Gabriela Maria Amaral Vallim Costa; Levi Fraga Pajehu; Juliao Soares De Souza Lima; Samuel De Assis Silva</i> .....	347
CALIBRAÇÃO DE MEDIDOR PORTÁTIL PARA ESTIMATIVA DE TEOR FOLIAR DE N EM FUNÇÃO DE ZONAS DE VIGOR VEGETATIVO DE VIDEIRAS FERTIRRIGADAS .....	358
<i>Luis Henrique Bassoi; Thassio Monteiro Menezes da Silva; Bruno Ricardo Silva Costa; Henrique Oldoni; Milene Corso Mitsuyuki</i> .....	358
PODA MECANIZADA NA MACIEIRA E SEUS EFEITOS NO ÍNDICE DE VEGETAÇÃO POR DIFERENÇA NORMALIZADA (NDVI) .....	363
<i>CHRISTIAN BREDEMEIER; VICTÓRIA REIS BORTOLUZ; BRUNO TADASHI CHIBA DA SILVA; NATALIA DE VAZ SCHAEFFER; ANNA ELISA PETERSEN GATELLI</i> .....	363
ESTIMATIVA DO VIGOR VEGETATIVO DE CAFEEIROS ARÁBICA UTILIZANDO SENSOR RGB EMBARCADO EM VEÍCULO AÉREO NÃO-TRIPULADO .....	369
<i>Samuel de Assis Silva; João Mendes Cicarini Hott; Levi Fraga Pajehú; Julião Soares de Souza Lima</i> .....	369
<b>6. Técnicas de análise de dados.....</b>	<b>377</b>
PLATAFORMA DE INTERNET DAS COISAS PARA MONITORAMENTO DE PRODUTIVIDADE E BEM-ESTAR ANIMAL EM SISTEMAS DE INTEGRAÇÃO LAVOURA-PECUÁRIA-FLORESTA.....	378
<i>Eduardo Antonio Speranza; Roberto Hiroshi Higa; Marcos Cezar Visoli; Claudinei Martins; Camilo Carromeu</i> .....	378
DELINEAMENTO DE ZONAS DE MANEJO PARA O PLANEJAMENTO DE EXPERIMENTAÇÃO ON-FARM NA CULTURA DO ALGODÃO.....	386
<i>Eduardo Antonio Speranza; Geovana Estevam de Sousa Olim; Ricardo Yassushi Inamasu; Carlos Manoel Pedro Vaz; Lúcio André de Castro Jorge</i> .....	386
TÉCNICAS DE MACHINE LEARNING NA PREDIÇÃO DA PRODUTIVIDADE DE ALGODÃO EM CAROÇO UTILIZANDO SENSORIAMENTO REMOTO POR SATÉLITE.....	396
<i>Renan Francisco Rimoldi Tavanti; Douglas Pedrini; Guilherme Morais; Anderson Cândido da Silva; Adriano Morel</i> .....	396
AValiação da Viabilidade do Pré-processamento de Espectros para Predição de Atributos do Solo em Tempo Real .....	403
<i>Ricardo Canal Filho; Marcelo Chan Fu Wei; José Paulo Molin</i> .....	403
ABORDAGENS COM COMPLEXIDADES DISTINTAS PARA O DELINEAMENTO DE UNIDADES DE GESTÃO DIFERENCIADA .....	413
<i>Henrique Oldoni; Joaquim Pedro de Lima; Agda Loureiro Gonçalves Oliveira; Lucas Rios do Amaral; Paulo Sérgio Graziano Magalhães</i> .....	413
EXPERIMENTAÇÃO ON-FARM NO SISTEMA DE AGRICULTURA DE PRECISÃO EM CANA-DE-AÇÚCAR .....	422
<i>CELIA REGINA GREGO; Cristina Aparecida Gonçalves Rodrigues ; Eduardo Antonio Speranza; Ariovaldo Luchiari Junior; Carlos César Ronquim</i> .....	422
VARIABILIDADE ESPACIAL DE PROPRIEDADES DO SOLO EM SISTEMAS INTEGRADOS .....	427
<i>NICOLLE LAURENTI; JOSIANE RODRIGUES; EDILSON DA SILVA GUIMARÃES; JOSÉ RICARDO MACEDO PEZZOPANE; ALBERTO CARLOS DE CAMPOS BERNARDI</i> .....	427
DESENVOLVIMENTO DE UM PLUGIN PARA INTERPOLAÇÃO POR KRIGAGEM ORDINARIA E MACHINE LEARNING NO QGIS.....	438
<i>GUSTAVO WILLAM PERIERA; DOMINGOS SÁRVIO MAGALHÃES VALENTE; DANIEL MARÇAL DE QUEIROZ; ANDRE LUIZ DE FREITAS COELHO</i> .....	438
TÉCNICAS DE SELEÇÃO DE ATRIBUTOS PARA PREDIÇÃO DE PRODUTIVIDADE DA SOJA .....	447

<i>Agda Loureiro Gonçalves Oliveira; Joaquim Pedro de Lima; Henrique Oldoni; Luiz Henrique Antunes Rodrigues; Lucas Rios do Amaral.....</i>	447
<b>7. Outros .....</b>	<b>456</b>
DISTRIBUIÇÃO LONGITUDINAL DE SEMENTES DE MILHO MENSURADA POR IMAGENS E ESTEIRA COM GRAXA .....	457
<i>Marcelo Chan Fu Wei; Maurício Martello; José Paulo Molin.....</i>	457
DESENVOLVIMENTO DE UM SISTEM EMBARCADO DE BAIXO CUSTO PARA MONITORAMENTO DE DESEMPENHO ENERGÉTICO DE TRATOR.....	465
<i>Thais Souza Santos; Mariana Dias Meneses; Eduardo José dos Santos; Agnaldo Santana Santos; Wellington Gonzaga do Vale .....</i>	465
ANÁLISE ESPACIAL DA ENTALPIA EM GALPÃO PARA CRIAÇÃO DE COELHOS BRANCOS NOVA ZELÂNDIA .....	470
<i>Patricia Ferreira Ponciano Ferraz; Rafaella Resende Andrade; Gabriel Araujo e Silva Ferraz; Luana Mendes Dos Santos; Maria Alice Junqueira Gouvêa Silva .....</i>	470
PROTÓTIPO DE SISTEMA PARA COLETA DE IMAGENS DE POMARES PARA PREVISÃO DE COLHEITA .....	477
<i>Darlan Alaor Selzlein; Carlos Moyses Abrahão Auzi Ribeiro; Luciano Gebler; Pedro Luiz de Paula Filho .....</i>	477

# **1. Agronomía/Manejo**

## Aplicação da metodologia *speckle* na investigação da classe textural do solo

Gustavo Di Chiacchio Faulin<sup>1</sup>; Rafael Alves da Silva<sup>2</sup>; Gildemberg Amorim Leal Junior<sup>3</sup>; Rita de Cássia Mendonça Sales Contini<sup>4</sup>; Sidney Leal da Silva<sup>5</sup>

<sup>1</sup>Eng<sup>o</sup> Agrônomo, Professor - Colegiado de Mecanização em Agricultura de Precisão, Fatec Shunji Nishimura de Pompeia - SP. gdfaulin@gmail.com / (14) 9 9614-1018; <sup>2</sup>Bolsista PIBITI-CNPq, Graduando - Automação Inicial, 'Prof. Miguel Reale'; <sup>3</sup>Eng<sup>o</sup> Agrônomo, Professor - Depto. de Fitossanidade, Universidade Federal de Alagoas; <sup>4</sup>Eng<sup>a</sup> Química, Professora - Desenvolvimento e aplicações de materiais avançados, Fatec São José dos Campos 'Prof. Jessen Vidal'; <sup>5</sup>Físico, Professor - Óptica e aplicações, Fatec Itaquera 'Prof. Miguel Reale'

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** O objetivo foi utilizar a técnica *Speckle* por reflexão aliada aos métodos computacionais fundamentados no THSP (acrônimo do inglês História Temporal do Padrão de *Speckle*) e Teoria de Erros, como uma alternativa na determinação da classe textural de solos agrícolas, aplicando uma metodologia com grande potencial para a agricultura de precisão, no intuito de reduzir o tempo das análises tradicionais em laboratório ou, até mesmo, substituí-las para fins de manejo da lavoura. Foram selecionadas 2 amostras de solos com percentuais de areia, silte e argila diferentes para a validação da metodologia *Speckle*, acondicionadas em 4 recipientes de maneira que cada amostra ficasse com duas espessuras distintas. Utilizando a técnica do *Speckle* por reflexão foi possível observar que as diferenças das espessuras não produziram interferências nas análises. A amostra de classe textural Franco Argilo Arenoso apresentou médias de intensidades relativas normalizadas maiores, em comparação com a amostra de classe textural Areia. Isto confirma a hipótese de que partículas menores de solo em relação as partículas de areia produzem maior dinâmica de interferência *Speckle*. A técnica de *Speckle* por reflexão aliada aos métodos computacionais fundamentados em THSP e Teoria dos Erros, foi capaz de distinguir as classes texturais nas amostras de solo, demonstrando seu potencial para estudos avançados nessa área.

**PALAVRAS-CHAVE:** granulometria do solo; laser; análise laboratorial

### APPLICATION OF THE SPECKLE METHODOLOGY TO DETERMINATION OF SOIL TEXTURAL CLASS

**ABSTRACT:** The objective was to use the reflection *Speckle* technique combined with computational methods based on THSP (Temporal History of *Speckle* Pattern) and Errors Theory, as an alternative to determining the textural class of agricultural soil, applying a methodology with great potential for precision agriculture, to reduce the time of traditional laboratory analyses or even replace them for crop management purposes. Two soil samples with different percentages of sand, silt and clay were selected for validation of the *Speckle* methodology, packed in 4 containers so that each sample had two different thicknesses. Using the reflection *Speckle* technique, it was possible to observe that the thickness differences did not interfere with the analyses. The sand clay loam textural class sample presented higher averages of normalized relative intensities, compared to the sand textural class sample. This confirms the hypothesis that smaller soil particles about sand particles produce greater *Speckle* interference dynamics. The Reflection *Speckle* technique combined with computational methods based on THSP and Error Theory was able to distinguish textural classes in soil samples, demonstrating its potential for advanced studies in this area.

**KEYWORDS:** soil granulometry; laser; laboratory analysis

**INTRODUÇÃO:** Na agricultura, a classe textural de um solo é uma variável ambiental importante, relacionada com o potencial produtivo das lavouras e os processos de degradação dos solos que, em conjunto com outros fatores, ajudam a direcionar um manejo mais adequado do solo (CENTENO et. al., 2017; KLEIN et. al., 2010; WHITE, 2005). Principalmente na agricultura de precisão, a determinação da granulometria do solo, desde a coleta de amostras georreferenciadas até a análise em laboratório, apresenta custos elevados,



elevado tempo na determinação dos resultados (NANNI e DEMATTÊ, 2006) e necessita de espaço físico nos laboratórios durante as análises das frações silte e argila. Utilizar a metodologia *Speckle* como uma alternativa inovadora na determinação da classe textural dos solos, torna-se um desafio promissor com grande potencial na obtenção de resultados rápidos e úteis para aplicações de manejo das lavouras agrícolas. *Speckle* é uma subárea da óptica que avalia o comportamento estático ou dinâmico do fenômeno de interferência em superfícies iluminadas por uma onda de luz coerente ao longo do tempo. Detalhes sobre a teoria e evolução de *Speckle* são apresentados por GASVIK, 2003; SILVA e MURAMATSU, 2007; GUENTHER, 2015; SALEH e TEICH, 2019. SANTOS et. al, 2020 apresentou um método sobre a correlação entre o fenômeno *biospeckle* e os diferentes níveis de umidade induzida em um Argissolo Vermelho-Amarelo. O objetivo desse estudo foi utilizar a técnica *Speckle* por reflexão aliada aos métodos computacionais fundamentados no THSP (acrônimo do inglês História Temporal do Padrão de Speckle) e Teoria de Erros, como uma alternativa na determinação da classe textural de solos agrícolas, aplicando uma metodologia com grande potencial para a agricultura de precisão, no intuito de reduzir o tempo das análises tradicionais em laboratórios ou, até mesmo, substituí-las para fins de manejo da lavoura.

**MATERIAIS E MÉTODOS:** Foram selecionadas 2 amostras de solos, posteriormente classificadas de acordo com a classe textural como Areia e como Franco Argilo Arenoso (Tabela 1). As amostras foram gentilmente cedidas pelo Laboratório de Solos e Tecido Vegetal da Fundação Shunji Nishimura de Tecnologia.

TABELA 1. Quantidades de areia, silte e argila e a sua classe textural das amostras de solo

Amostras	Areia (g kg <sup>-1</sup> )	Silte (g kg <sup>-1</sup> )	Argila (g kg <sup>-1</sup> )	Classe Textural
106489/4	938	6	56	Areia
111214/9	576	178	246	Franco Argilo Arenoso

As amostras foram acondicionadas em 4 cápsulas de acrílico com revestimento de EVA preto, para diminuir a dispersão da luz, divididas em 2 espessuras para cada amostra (Figura 1).




FIGURA 1. Amostras de solo de classe textural areia (i) e franco argilo arenoso (ii), ambas divididas em menos espessa (A) e mais espessa (B)

A técnica óptica utilizada foi uma configuração experimental do interferômetro *Speckle* por reflexão (Figura 2), do ponto de vista ondulatório, a luz laser de uma fonte de He-Ne (hélio-neônio)<sup>1</sup> com comprimento de onda de  $632,8 \times 10^{-9}$  m e potência de  $2,1 \times 10^{-2}$  W, passa por um filtro espacial<sup>2</sup>, composto por uma lente objetiva

de  $10 \times$  e um pinhole com diâmetro de  $2,5 \times 10^{-5}$  m, cuja função é transformar a onda espacial gaussiana em esférica. Em seguida, a luz atravessa uma lente plano-convexa<sup>3</sup> que a transforma em onda plana, para que os raios de luz se tornem paralelos, o que facilitou o controle sobre a luz utilizada no experimento e, também, simplificou o trabalho matemático realizado na análise de dados, já que a onda plana pode ser interpretada utilizando-se um sistema inercial de coordenadas cartesianas. A seguir, a resultante de luz passa por uma íris<sup>4</sup> que define o diâmetro de  $(2,0 \pm 0,2) \times 10^{-2}$  m adequado à observação. Finalmente, a luz incide em um espelho plano<sup>5</sup>, que a direciona para a amostra<sup>6</sup> na obtenção do padrão de interferência. Esse padrão foi observado por uma câmera digital<sup>7</sup> e um vídeo, para cada amostra, foi armazenado como arquivo digital em um computador<sup>8</sup>.




FIGURA 2. Foto da configuração experimental: interferômetro Speckle por reflexão. Laser He-Ne (1); filtro espacial (2), lente plano-convexa (3); íris (4), espelho plano (5), amostra (6), câmera digital (7) e computador (8).

O processo de captura de dados foi organizado coletando 10 vídeos com um tempo  $t=10$  s de exposição em 10 regiões distintas de cada amostra para as duas espessuras. O método computacional teve o propósito principal de apresentar, primeiramente, resultados qualitativos, por observação direta da contrastação das imagens dos padrões de interferência armazenadas em arquivos de vídeos e, em seguida, resultados quantitativos por método computacional gráfico das intensidades médias relativas em função das regiões de observação selecionadas na amostra. As teorias que fundamentaram o método computacional estiveram associadas aos tradicionais métodos THSP e Teoria de Erros (VUOLO, 1992). Os procedimentos para a análise foram: (i) cada vídeo, que corresponde a uma região de observação em uma determinada amostra, foi separado em quadros, *frames*; (ii) em cada vídeo retirou-se 1 linha horizontal de pixels de cada quadro e cada linha foi organizada verticalmente em sequência em um arquivo denominado *THSP*.

**RESULTADOS E DISCUSSÃO:** Um vídeo comparativo das interferências entre as amostras, pode ser visto no link (Interferências Speckle). O vídeo mostra uma maior velocidade para o movimento na superfície da amostra com classe textural Franco Argilo Arenoso (amostra 111214/9), comparado ao movimento na superfície da amostra com classe textural Areia (amostra 106489/4). Os movimentos estão associados às mudanças nos posicionamentos das interferências *Speckle*, mesmo com as superfícies “estáticas”. Este resultado aponta que as superfícies com partículas maiores, classe textural Areia, produzem mais absorções da luz e, portanto, menos interferências devido ao menor espalhamento. Por outro lado, as superfícies com mais partículas menores, em relação a amostra com classe textural Areia, produzem menores absorções da luz e, portanto, mais interferências devido ao maior espalhamento. Essa análise, confirma a hipótese levantada no objetivo do trabalho. A Figura 3 apresenta os resultados dos contrastes das interferências *Speckle* entre as amostras nas duas espessuras, por meio de distribuições de intensidades médias relativas em função das regiões observadas.



FIGURA 3. Distribuições das intensidades médias relativas normalizadas versus regiões de observação das interferências Speckle, dos vídeos coletados das amostras menos espessas (a) e mais espessas (b)

Verifica-se que as diferenças das espessuras não produziram contrastes relevantes nas distribuições, já que as intensidades médias relativas se apresentaram muito similares. Em todos os gráficos, no entanto, nota-se que as distribuições representativas da amostra com classe textural Franco Argilo Arenoso (amostra 111214/9) estão com as médias de intensidades relativas normalizadas maiores, em comparação com as distribuições que representam a amostra de classe textural Areia (amostra 106489/4). Isto confirma a hipótese de que as amostras de solo com partículas menores em relação as partículas de areia, produzem maior dinâmica de interferência *Speckle*, já que as intensidades estão associadas à maior ou menor “dinâmica” do fenômeno.

**CONCLUSÃO:** A metodologia Speckle foi capaz de distinguir as amostras de solo com classes texturais diferentes, demonstrando potencial para estudos avançados nessa área. A espessura das amostras submetidas ao laser não provocou diferença na distinção entre as amostras da mesma classe textural.

#### AGRADECIMENTOS:

Ao Laboratório de Solos e Tecido Vegetal da Fundação Shunji Nishimura de Tecnologia pelo fornecimento das amostras de solo.

#### REFERÊNCIAS

- CENTENO, L.N.; GUEVARA, M.D.F.; CECCONELLO, S.T.; DE SOUSA, R.O.; TIMM, L.C. Textura do solo: conceitos e aplicações em solos arenosos. **Revista Brasileira de Engenharia e Sustentabilidade**, v. 4, n. 1, p. 31-37, 2017.
- GASVIK, K.J. **Optical metrology**. John Wiley & Sons, 2003. 360 p.
- GUENTHER, B.D. **Modern Optics**. Oxford University Press, 2015. 752 p.
- KLEIN, V.A.; BASEGGIO, M.; MADALOSSO, T.; MARCOLIN, C.D. Textura do solo e a estimativa do teor de água no ponto de murcha permanente com psicrômetro. **Ciência Rural**, v. 40, p. 1550-1556, 2010.
- NANNI, M.R.; DEMATTÊ, J.A.M. Spectral reflectance methodology in comparison to traditional soil analysis. **Soil Science Society of America Journal**, v. 70, n. 2, p. 393-407, 2006.
- SALEH, B.E.A.; TEICH, M.C. **Fundamentals of photonics**. John Wiley & Sons, 2019. 1520 p.

SANTOS, L.D.V.; ENES, A.M.; HOLANDA, F.S.R.; OLIVEIRA, C.V.S.; PEDROTI, A. Avaliação do comportamento do biospeckle em diferentes níveis de umidade do solo. **Brasilian Journal of Development**, v. 6, n. 7, p. 52891-52908, 2020.

SILVA, E.R.; MURAMATSU, M. O fenômeno do speckle como introdução à metrologia óptica no laboratório didático. **Revista Brasileira de Ensino de Física**, v. 29, p. 283-286, 2007.

VUOLO, J.H. **Fundamentos da Teoria de Erros**. 2ª edição. São Paulo: Editora Edgard Blucher Ltda, 1996. 264 p.

WHITE, R.E. **Principles and practice of soil science: the soil as a natural resource**. John Wiley & Sons, 2005. 384 p.



# FATORES QUE IMPACTAM A RESPOSTA DA CANA-DE-AÇÚCAR AO NITROGÊNIO PARA FINS DE MANEJO LOCALIZADO

Guilherme Martineli Sanches<sup>1</sup>; Rafael Otto<sup>2</sup>; Etori Veronezi<sup>3</sup>; Mariana Rodrigues<sup>4</sup>

<sup>1</sup>Engenheiro Agrícola, Pós doutorando - Departamento de Ciência do Solo, ESALQ - USP, Piracicaba, SP. guilhermesanches@usp.br / (14) 9 9164-8711; <sup>2</sup>Engenheiro Agrônomo, Professor Doutor - Departamento de Ciência do Solo, ESALQ - USP, Piracicaba, SP; <sup>3</sup>Engenheiro Agrônomo, Graduando - Departamento de Ciência do Solo, ESALQ - USP, Piracicaba, SP; <sup>4</sup>Engenheiro Agrônomo, Graduando - Departamento de Ciência do Solo, ESALQ - USP, Piracicaba, SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** O nitrogênio (N) é um dos nutrientes mais aplicados nas lavouras e o que apresenta maior potencial de contaminar o ambiente. O aumento do consumo de fertilizantes nitrogenados é um dos principais fatores que afetam a sustentabilidade do processo de produção de bioenergia a partir da cana-de-açúcar. Atualmente as recomendações de N na cana-de-açúcar são baseadas apenas no fator produtividade esperada. No entanto, diversos fatores da planta, solo e clima podem afetar a resposta da cana-de-açúcar à adubação nitrogenada. Diante deste contexto, o objetivo do presente trabalho foi investigar quais são os principais fatores do solo e planta que afetam a resposta da cana-de-açúcar ao N em trabalhos da literatura utilizando análise multivariada e meta-análise, visando permitir a construção de modelos mais robustos para manejo localizado de N. Uma ampla revisão de literatura (130 experimentos) mostrou que 60% do total de experimentos avaliados foram responsivos ao N. A média geral da taxa ótima ( $N_{opt}$ ) dos experimentos responsivos foi de 118,20 (kg N) ha<sup>-1</sup>. Os resultados mostraram que solos com baixo potencial produtivo (< 70 t ha<sup>-1</sup>) apresentaram  $N_{opt}$  maiores quando comparados a solos de alto potencial produtivo (> 100 t ha<sup>-1</sup>);  $N_{opt}$  = 120,18 e 111,80 (kg N) ha<sup>-1</sup>, respectivamente, para solos com baixo e alto potencial produtivo. Dentre os fatores da planta analisados, a variedade da cultura, a dose de N e a localização da área são os três fatores que mais afetam a resposta ao N. Dos fatores do solo, a textura e o conteúdo de matéria orgânica são os que mais impactam a resposta da cultura ao N.

**PALAVRAS-CHAVE:** taxa ótima de nitrogênio; random forest; adubação nitrogenada

## FACTORS THAT IMPACT SUGARCANE RESPONSE TO NITROGEN FOR SITE-SPECIFIC MANAGEMENT PURPOSES

**ABSTRACT:** Nitrogen (N) is one of the most widely used fertilizers in crops and the most harmful to the environment. The increased consumption of nitrogen fertilizers is one of the main factors that affect the sustainability of the bioenergy production process from sugarcane. Currently, N recommendations in sugarcane are based only on the expected yield. However, several factors of the plant, soil and climate can affect the response of sugarcane to N fertilization. In this context, the objective of the present study was to investigate what are the main soil and plant factors that affect the N response to sugarcane in researches available in the literature using multivariate and meta-analysis, aiming to guide models for nitrogen site-specific management. A wide literature review (130 experiments) showed that 60% of the total evaluated experiments were responsive to N. The general average of the N optimal rate ( $N_{opt}$ ) of the responsive experiments was 118.20 (kg N) ha<sup>-1</sup>. The results showed that soils with low yield potential (< 70 t ha<sup>-1</sup>) presented higher  $N_{opt}$  when compared to soils with high yield potential (> 100 t ha<sup>-1</sup>);  $N_{opt}$  = 120.18 and 111.80 (kg N) ha<sup>-1</sup>, respectively, for soils with low and high yield potential. Among the factors of the plant assessed, the crop variety, the N application rate and the geolocation of the field are the three factors that most affect the N responsiveness. About soil factors, the soil texture and the organic matter content are the ones that most impact the crop's response to N.

**KEYWORDS:** nitrogen optimal rate; random forest; nitrogen fertilization

**INTRODUÇÃO:** A adubação nitrogenada na agricultura contribui significativamente para as emissões de  $N_2O$  (Crutzen et al., 2008; de Vries e Bardgett, 2012; Soares et al., 2015), correspondendo a 310 vezes o poder de emissão de GEE do  $CO_2$ . Além disso, não existem métodos diagnósticos confiáveis para caracterização da disponibilidade de nitrogênio (N) nos solos agrícolas. A recomendação de adubação nitrogenada para cana-de-açúcar é baseada exclusivamente no conceito de produtividade esperada (Spironello et al., 1997). Alguns autores destacam que, para atender as necessidades nutricionais da cana-de-açúcar, recomenda-se aplicar entre 120 e 200  $kg\ ha^{-1}$  de N nas condições brasileiras (Cantarella e Rossetto, 2014). Entretanto, estes valores são elevados quando comparados às doses usualmente empregadas em áreas comerciais. Além disso, é evidente que a taxa ótima de N pode depender de vários fatores, como características do solo (pH, CTC, matéria orgânica, teor de argila, aeração e compactação), condições climáticas (temperatura e pluviosidade) e práticas agronômicas (preparo e rotação de culturas) (Subbarao et al., 2006). A metodologia proposta por Khan et al. (2001) e Mulvaney et al. (2001), denominada de “soil based N approach for guiding N recommendation” (Mulvaney et al., 2006), apesar de não utilizada na prática, é buscada há décadas como uma estratégia de otimizar a recomendação de adubação nitrogenada das culturas, uma vez que o solo é o principal reservatório de N para as culturas (Dourado-Neto et al., 2010; Franco et al., 2011). Entretanto, utilizando solos de 21 experimentos de campo, Mariano et al. (2017) demonstrou resultados pouco favoráveis em utilizar índices químicos para identificar a responsividade da cana-de-açúcar ao N. Como ainda não existe consenso na literatura da possibilidade de utilização de métodos químicos para diagnosticar o status de N do solo, outra estratégia é avaliar fatores que afetam a responsividade da cana-de-açúcar ao N. Otto et al. (2016) observaram que a resposta da cana-de-açúcar à adubação nitrogenada no Brasil é baixa, sendo atribuída pelos autores às condições de cultivo da cultura, como preservação da palha na superfície, reaproveitamento de resíduos industriais (torta de filtro, cinzas e vinhaça) e ao plantio de leguminosas em rotação, que aumentam a disponibilidade de N do solo e conseqüentemente diminuem a sua responsividade. Portanto, torna-se necessário revisitar estudos de resposta da cana-de-açúcar ao N, elencando quais fatores do solo e planta podem estar associados à responsividade da cana-de-açúcar ao N, permitindo incluir estes parâmetros em modelos mais eficientes de recomendação, buscando o máximo retorno econômico e sustentabilidade ambiental dentro do contexto de manejo localizado e agricultura de precisão. O presente projeto tem como objetivo avaliar os fatores do solo e planta que afetam a resposta da cana-de-açúcar ao N em trabalhos disponíveis na literatura, utilizando análise multivariada e meta-análise, visando nortear a construção de modelos para manejo localizado das lavouras.

**MATERIAIS E MÉTODOS:** Foram revisados 14 trabalhos publicados na literatura (Tabela 1), totalizando 130 experimentos e 586 parcelas experimentais de resposta da cana-de-açúcar à adubação nitrogenada. Foram extraídas as informações de região do experimento, variedade utilizada, doses de N aplicadas, época de corte, teor de argila, matéria orgânica (MO), capacidade de troca catiônica (CTC) do solo e produtividade das parcelas experimentais. Todos os trabalhos revisados são provenientes do estado de São Paulo, maior produtor de cana-de-açúcar no Brasil (CONAB, 2019), sendo Ribeirão Preto, Piracicaba e São José do Rio Preto as principais regiões onde os trabalhos foram desenvolvidos (Figura 1 – a). A maioria dos trabalhos revisados foram desenvolvidos após 2010, com colheita crua de cana-de-açúcar (Figura 1 – b). Segunda e terceira soca foi a idade da cana-de-açúcar em mais de 80% dos trabalhos revisados (Figura 1 – c). As duas variedades mais utilizadas nos estudos foram IAC955000 (25%) e SP813250 (20%) (Figura 1 – d).

#### *Análise de Dados*

A avaliação da resposta da cana-de-açúcar à adubação nitrogenada, em função dos parâmetros de solo e planta, foi realizada por etapas (Figura 2). Primeiramente foram extraídas as principais informações de solo e planta de todos os experimentos avaliados. Para cada conjunto de parcelas experimentais ajustou-se os modelos lineares e quadráticos das doses de N em função da produtividade. Adotou-se como parâmetro uma significância de 5% ( $\alpha = 0,05$ ). Quando nenhum dos ajustes foi significativo, o experimento foi classificado como não responsivo ao N. Para os ajustes significativos, calculou-se a dose ótima de N ( $N_{opt}$ ) e o nitrogênio requerido ( $N_{req.}$  – Equação 1). Para o modelo quadrático a  $N_{opt}$  corresponde ao ponto de inflexão da curva. Já para o modelo linear adotou-se a  $N_{opt}$  como sendo 80% da dose máxima do experimento.

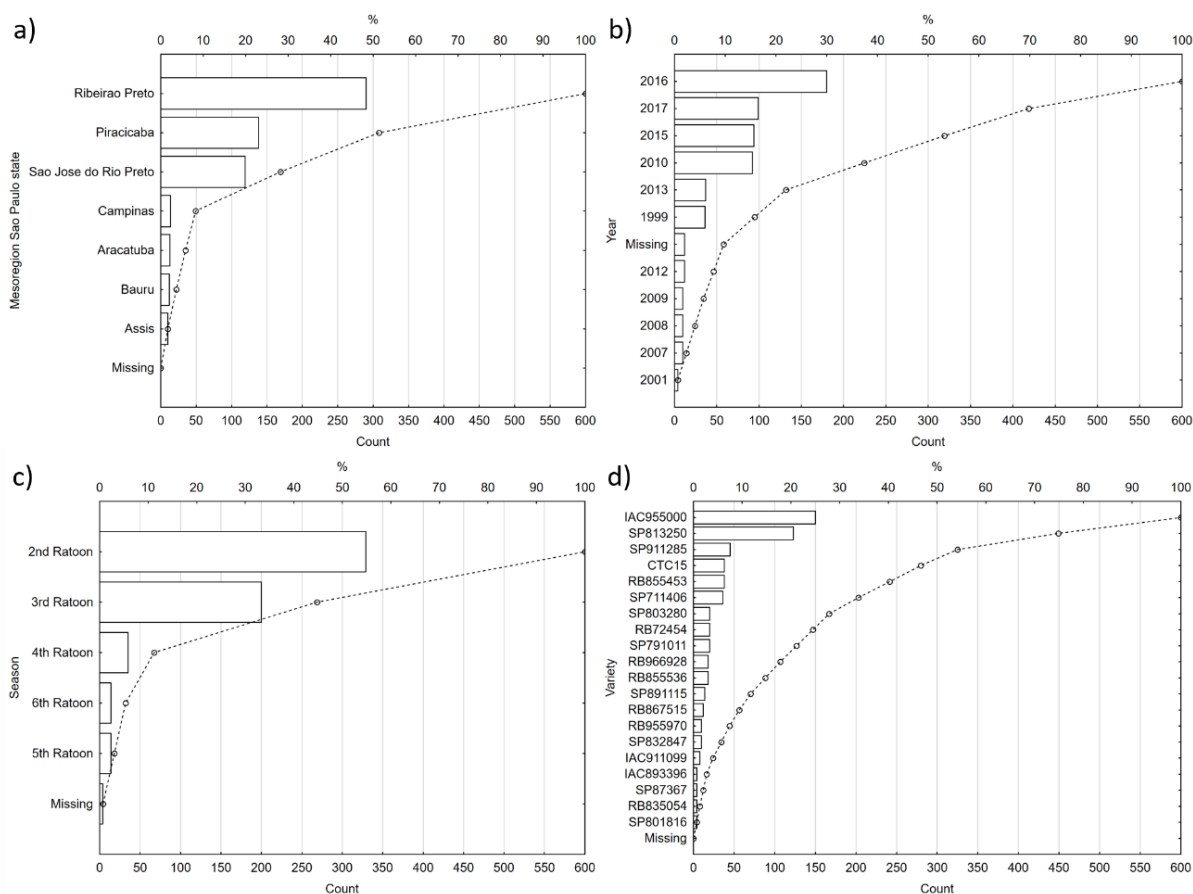
$$N_{req.} = N_{opt.} / \text{Produtividade (1)}$$

em que:  $N_{req}$  – nitrogênio requerido pela planta [(kg N) t<sup>-1</sup>],  $N_{opt}$  – dose ótima de nitrogênio [(kg N) ha<sup>-1</sup>];  
 Produtividade – produtividade correspondente à  $N_{opt}$  [t ha<sup>-1</sup>].

TABELA 1. Referência bibliográfica dos experimentos de curvas de resposta de N na cana-de-açúcar utilizados no estudo. **Survey of N-response curve trials in sugarcane fields assessed.**

Trial	N <sub>trial</sub>	N <sub>plots</sub>	Referência
1 - 8	8	37	Otto et al. (2013)
9 - 10	2	10	Prado and Pancelli (2008)
11 - 25	15	60	Rosseto et al. (2010)
26 - 46	21	94	Mariano (2015)
47 - 54	8	32	Fortes (2010)
55	1	4	Vieira et al. (2010)
56 - 59	4	24	Castro (2012)
60	1	4	Penatti et al. (2001)
61 - 72	12	36	Orlando Filho et al. (1999)
73 - 84	12	36	Moreira (2017)
85 - 114	30	150	Castro (2016)
115 - 120	6	30	Leite (2016)
121 - 129	9	63	Boschiero (2017)
130	1	6	Vitti et al. (2007)

N<sub>trial</sub> – número de experimentos; N<sub>plots</sub> – número de parcelas experimentais.



Uma imagem contendo texto, mapa Descrição gerada automaticamente

FIGURA 1. Caracterização do conjunto de dados dos experimentos de curva de resposta de N na cana-de-açúcar por mesorregião (a), ano (b), época de corte (c) e variedade (d). **Characterization of dataset of N-response curve trials in sugarcane fields by mesoregion (a), year (b), ratoon (c) and variety (d).**

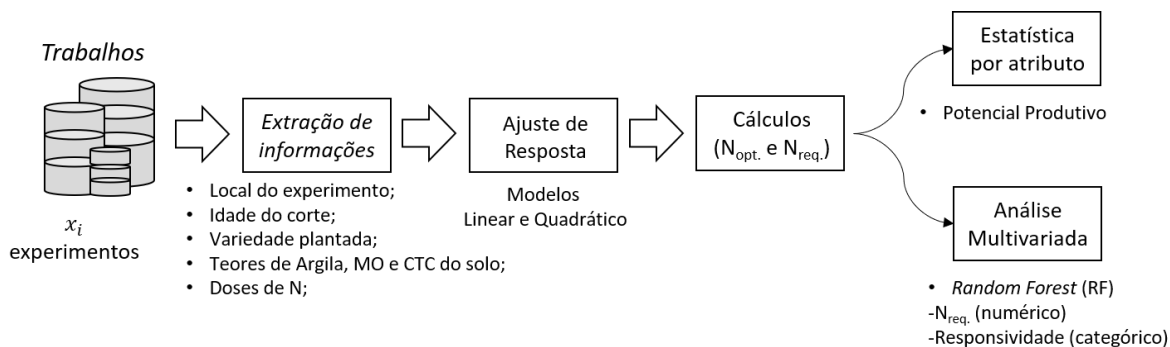


FIGURE 2. Etapas do processo de análise de dados. **Steps on data analyses process.**

A média dos parâmetros  $N_{opt}$  e  $N_{req}$  foram então calculadas de acordo com classes estabelecidas de potencial produtivo (baixo: produtividade  $< 70 \text{ t ha}^{-1}$ ; médio: produtividade  $70\text{-}100 \text{ t ha}^{-1}$  e alto: produtividade  $> 100 \text{ t ha}^{-1}$ ). Para estabelecer as classes de potencial produtivo adotou-se a produtividade das parcelas experimentais controle (dose N = zero). Para identificar quais são os principais parâmetros do solo e planta que impactam diretamente a resposta ao N, aplicou-se a análise multivariada de *Random Forest* (RF) (Breiman, 2001). Foram utilizadas duas abordagens para esta análise. Na primeira abordagem utilizou-se como variável resposta o  $N_{req}$  calculado (Eq. 1), sendo este um atributo numérico. Na segunda abordagem a variável resposta foi a responsividade da cultura ao N, sendo portanto um atributo binário com valores “SIM” e “NÃO”. Para ambas abordagens foram utilizadas um conjunto de 100 árvores de decisão e todos os atributos do solo e planta avaliados. Para treinamento e teste, 70% e 30% do total de dados foram utilizados, respectivamente. Avaliou-

se ao final o gráfico de importância dos atributos para identificar aqueles que mais impactam diretamente o requerimento de N e a responsividade da cultura.

**RESULTADOS E DISCUSSÃO:** Do total de experimentos avaliados na presente revisão, 79 foram responsivos à aplicação de N, correspondendo a ~60% do total. Otto et al. (2016) em uma ampla revisão chegaram que 51% e 24% dos experimentos avaliados foram moderadamente e altamente responsivos ao N, respectivamente. A média geral da  $N_{opt}$  e  $N_{req.}$  dos 79 experimentos responsivos foi de 118,2 (kg N) ha<sup>-1</sup> e 1,21 (kg N) t<sup>-1</sup>, respectivamente. Alguns autores destacam que, para atender as necessidades nutricionais da cana-de-açúcar, recomenda-se aplicar entre 120 e 200 kg ha<sup>-1</sup> de N nas condições brasileiras (Cantarella e Rossetto, 2014), sendo superior à média dos experimentos aqui avaliados. Tal fato mostra que para atender as exigências nutricionais da cana-de-açúcar as doses podem ser menores do que as recomendadas atualmente. A adoção intensiva da mecanização da colheita de cana-de-açúcar, que vem proporcionando a manutenção de grandes quantidades de palha nas lavouras, pode explicar a menor dose ótima encontrada. Segundo Menandro et al. (2017), a palha da cana-de-açúcar é composta por 60% de folhas secas e 40% de folhas verdes, sendo que as folhas verdes correspondem a 70% da concentração de N, P e K na palha. De acordo com os autores, 5,6 t ha<sup>-1</sup> de folhas verdes apresentam potencial de reciclar 48, 15 e 80 kg ha<sup>-1</sup> de N, P<sub>2</sub>O<sub>5</sub> e K<sub>2</sub>O. Desta forma, as quantidades de N reciclado pela palha podem promover a menor necessidade de fertilizantes minerais, especialmente o N, para atender as exigências nutricionais da planta. Essa baixa resposta ao N também foi atribuído por Otto et al. (2016) pela preservação da palha na superfície, reaproveitamento de resíduos industriais (torta de filtro, cinzas e vinhaça) e ao plantio de leguminosas em rotação.

Como relatado por Subbarao et al (2006), a eficiência de uso do nitrogênio (EUN) depende de diversas características, como atributos do solo, condições climáticas (temperatura e pluviosidade) e práticas agrônômicas (preparo e rotação de culturas). Os resultados mostram que solos com menor potencial produtivo, isto é, produtividade abaixo de 70 t ha<sup>-1</sup>, apresentaram valores de  $N_{opt}$  e  $N_{req.}$  (120,18 (kg N) ha<sup>-1</sup> e 1,57 (kg N) t<sup>-1</sup>, respectivamente) maiores quando comparados a solos de maior potencial produtivo (111,80 (kg N) ha<sup>-1</sup> e 0,92 (kg N) t<sup>-1</sup>, respectivamente). Tal fato mostra que os atributos de textura do solo, MO e CTC, fatores determinantes para definição do potencial produtivo das lavouras (Sanches et al., 2019b), podem impactar diretamente na  $N_{opt}$  e  $N_{req.}$ . Diante deste contexto, os resultados apresentados mostram que a recomendação de N pode ser vinculada aos parâmetros que definem o potencial produtivo do solo. Dentro das tecnologias de agricultura de precisão, a condutividade elétrica aparente (CEa) do solo tem se mostrado como um método bem-sucedido de avaliar com rapidez, alta resolução e baixo custo, a variabilidade da fertilidade (Sudduth et al., 2005) e do potencial produtivo dos solos (Sanches et al., 2019; Corwin e Lesch, 2005). Alguns autores também já investigaram a utilização da CEa para aplicações de N nas lavouras (Wong e Asseng, 2006; Cockx et al., 2005). Porém a literatura ainda não traz resultados de como esta informação pode ser utilizada em campos de cana-de-açúcar para otimização da aplicação de N. Desta forma, os resultados apresentados aqui mostram grande potencial da utilização da CEa para delimitação do potencial produtivo do solo para guiar uma fertilização nitrogenada mais eficiente.

TABLE 3. Taxa ótima de nitrogênio ( $N_{opt}$ ), requerimento de nitrogênio ( $N_{req.}$ ) e ganhos de produtividade de acordo com o potencial produtivo da lavoura. **Nitrogen optimal rate ( $N_{opt}$ ), N requirement ( $N_{req.}$ ) and yield gain according yield potential.**

		$N_{opt}$	$N_{req.}$	Ganho de Produtividade	
		(kg N) ha <sup>-1</sup>	(kg N) t <sup>-1</sup>	%	t ha <sup>-1</sup>
Potencial Produtivo	Baixo	120.18	1.57	30.59	17.33
	Médio	122.03	1.21	24.39	20.56
	Alto	111.80	0.92	11.24	12.15

O potencial produtivo da lavoura está diretamente ligada ao  $N_{req.}$ . Os 79 experimentos responsivos ao N avaliados no presente trabalho apresentaram que a produtividade da lavoura foi inversamente proporcional ao  $N_{req.}$  (Tabela 3). Sendo uma das recomendações mais utilizadas pelos produtores de cana-de-açúcar, Raij et al.

(1997) trazem que a adubação de cana soca deve variar de 60 a 120 (kg N) ha<sup>-1</sup>, sendo a dose recomendada diretamente proporcional à produtividade esperada. Para produtividades maiores que 100 t ha<sup>-1</sup> os autores recomendam uma dose de 120 (kg N) ha<sup>-1</sup>, ou seja, 1,2 kg N para cada tonelada de cana produzida. No entanto, os resultados da presente pesquisa mostram que a recomendação de aplicação de N pode ser menor para lavouras com potenciais produtivos maiores, reduzindo a recomendação proposta por Raij et al. (1997) de 1,20 (kg N) t<sup>-1</sup>. Desta forma, lavouras de alto potencial produtivo podem receber menores quantidades de N, contribuindo para uma aplicação ambientalmente mais sustentável dos campos de cultivo. A extinção da queima dos canaviais brasileiros e a conseqüente mudança para uma mecanização mais intensiva da colheita (Franco et al., 2018) são fatores que podem explicar a menor necessidade de N em lavouras de alta produtividade. A grande disponibilidade de palha na superfície do solo, como relatado por Menandro et al. (2017), vêm ocasionando a mudança na disponibilidade de N nos solos, promovendo menores necessidades de suplementação de N via adubação mineral; diferentemente do cenário dos anos 90 quando as recomendações foram propostas e os campos ainda sofriam a queima da palha para colheita da cultura. Desta forma, faz-se necessário revisar as recomendações de aplicação de N nas lavouras. Por outro lado, os resultados encontrados na presente pesquisa podem contribuir também para redução das emissões de GEE. Enquanto solos arenosos (de menor potencial produtivo) emitem menores quantidade de N<sub>2</sub>O, independentemente na fonte de N utilizada para adubação, em comparação a solos argilosos (Zhu et al., 2013), os resultados mostram que é possível aplicar menor quantidade de N em solos argilosos (maior potencial produtivo), contribuindo para a redução dos GEE.

Os parâmetros da planta avaliados apresentaram maior importância no requerimento de N quando comparados aos parâmetros do solo (Figura 3). Entre os parâmetros avaliados, a variedade da cultura foi a que mais impactou no N<sub>req.</sub> (Figura 3 – a) e a responsividade da cultura (Figura 3 – b). Kolln (2016) avaliando 18 genótipos de cana-de-açúcar concluíram que o requerimento de N é impactada diretamente pela variedade da cultura, concluindo que as recomendações de aplicação de N atuais são imprecisas por não considerarem a EUN dos genótipos disponíveis comercialmente. A dose de N foi o segundo parâmetro que mais impactou o N<sub>req.</sub>. Thorburn et al. (2017) investigando os parâmetros que guiam a EUN em canaviais australianos mostraram que a dose de N também foi um dos principais fatores em diversas simulações conduzidas, colaborando com os resultados aqui apresentados. A região do experimento foi o terceiro parâmetro mais importante, tanto para o N<sub>req.</sub> quanto para a responsividade da cultura. A disponibilidade hídrica da região, parâmetro não avaliado no presente trabalho, pode ser um dos motivos que explicam a importância da região para o N<sub>req.</sub>. Castro et al. (2019) avaliando a aplicação de N em diferentes épocas do ano (início, meio e fim de safra) concluíram que a menor disponibilidade hídrica no meio da safra impactou diretamente o N<sub>req.</sub>, levando a uma diminuição desta. Os autores ainda concluem que aplicações superiores a 150 (kg N) ha<sup>-1</sup> podem não ser economicamente viáveis. Entre os três fatores de solo analisados, o conteúdo de argila mostrou-se mais importante quando comparado ao conteúdo de MO e CTC para o N<sub>req.</sub>. Quando se fala em responsividade, a CTC do solo passa a ser mais importante quando comparada à textura, saturação por bases (V%) e MO. Futuros trabalhos devem investigar qual o impacto destes atributos do solo no N<sub>req.</sub>, permitindo maior assertividade nas recomendações atuais de N em cana-de-açúcar. Por fim, os resultados da presente pesquisa mostram que as recomendações de N em cana-de-açúcar não devem basear-se somente na produtividade esperada, mas também nos parâmetros de variedade e fatores do solo.

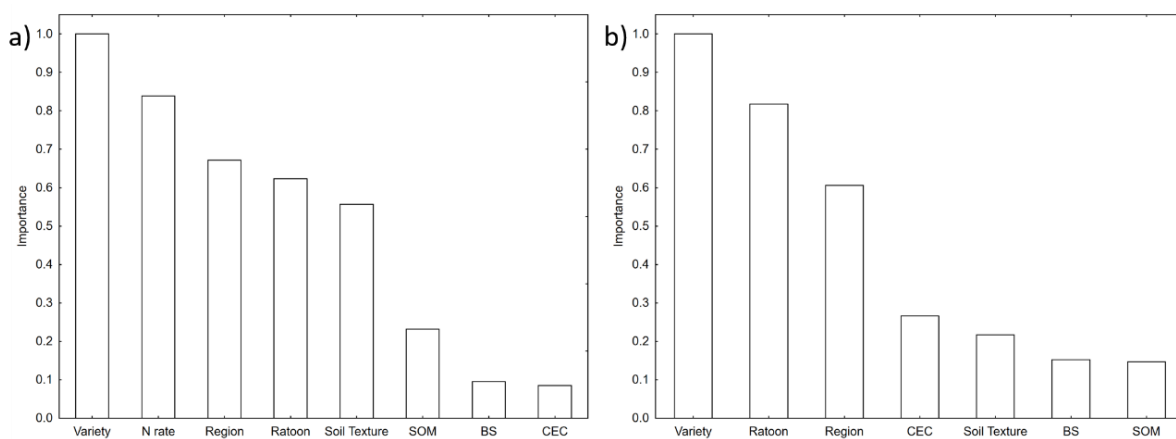


FIGURE 3. Gráfico de importância do algoritmo *Random Forest* (RF) aplicado ao requerimento de N (a) e responsividade da cultura ao nitrogênio (b) do levantamento de experimentos de curva de resposta N. **Importance plot from random forest (RF) algorithm applied to nitrogen requirement (a) and nitrogen responsiveness (b) from survey of N-response curve trials.**

**CONCLUSÃO:** As recomendações atuais para aplicação de N levam em consideração apenas o potencial produtivo das lavouras, negligenciando os fatores da planta e solo que permitem maximizar a EUN. As recomendações propõem ainda maiores taxas de aplicação em lavouras de maior potencial produtivo, em oposição aos resultados da presente pesquisa. Modelos de recomendação futuros devem incluir parâmetros de variedade e atributos do solo para racionalização da adubação nitrogenada. Os achados mostram que é possível racionalizar a aplicação de N para sustentabilidade da produção. Uma ampla revisão mostrou que campos de alto potencial produtivo permitem aplicações menores de N para expressão da sua máxima produtividade potencial.

#### **AGRADECIMENTOS:**

À Fundação de Amparo à pesquisa do Estado de São Paulo (FAPESP – Processos 2018/10225-3, 2019/18779-0) e ao Conselho Nacional de Ciência e Tecnologia (CNPq).

#### **REFERÊNCIAS**

- BOSCHIERO, B.N. 2017. Adubação nitrogenada em soqueiras de cana-de-açúcar: influência do uso em longo prazo de fontes e/ou doses de nitrogênio. **Thesis**, University of São Paulo State.
- BREIMAN, L., 2001. Random forests. **Machine Learning** 45:5-32.
- 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.
- CASTRO, S.G.Q. 2012. Sistemas de manejo em colheita e cultivo associados à adubação nitrogenada da cana-de-açúcar: aspectos quali-quantitativos da produção. **Thesis, University of São Paulo State**.
- CASTRO, S.G.Q. 2017. Manejo da adubação nitrogenada em cana-de-açúcar e diagnose por meio de sensores de dossel. Tese (Doutor em Engenharia Agrícola). Faculdade de Engenharia Agrícola. Universidade Estadual de Campinas, **FEAGRI/UNICAMP**, 2016. 129p.
- CASTRO, S.G.Q.; Rossi Neto, J.; Kolln, O.T.; Borges, B.M.M.N.; Franco, H.C.J. 2019. Decision-making on the optimum timing for nitrogen fertilization on sugarcane ratoon. **Scientia Agricola** 76:237-242.
- COCKX, L.; VAN MEIRVENNE, M.; HOFMAN, G. 2005. Characterization of nitrogen dynamics in a pasture soil by electromagnetic induction. **Biol. Fertil. Soils** 42:24–30.
- COMPANHIA NACIONAL DO ABASTECIMENTO (CONAB). 2018. Acompanhamento da safra Brasileira. Cana-de-açúcar, **SAFRA 2017/18 Primeiro Levantamento Abril/2019**. Brasília, DF, 62p
- CRUTZEN, P.J.; MOSIER, A.R.; SMITH, K.A.; WINIWARTER, W. 2008. N<sub>2</sub>O release from agro-biofuel production negates global warming reduction by replacing fossil fuels. **Atmospheric Chemistry and Physics** 8:389–395.
- 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, 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.
- FORTES, C. 2010. Produtividade de cana-de-açúcar em função da adubação nitrogenada e da decomposição da palhada em ciclos consecutivos. **Thesis, University of São Paulo**
- 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.
- KHAN, S.A., MULVANEY, R.L., HOEFT, R.G. 2001. A simple soil test for detecting sites that are nonresponsive to nitrogen fertilization. **Soil Sci Soc Am J** 65:1751-1760.
- KOLLN, O. T. 2016. Eficiência de uso de nitrogênio pela cana-de-açúcar: diferenças genotípicas, preferência por amônio e emissão de N<sub>2</sub>O Piracicaba. **Tese apresentada no Centro de Energia Nuclear na Agricultura (CENA) da Universidade de São Paulo (USP)**. 119 p.
- LEITE, J.M. 2016. Eficiência agronômica da adubação nitrogenada associada à aplicação de substâncias húmicas em cana-de-açúcar. **University of São Paulo, Thesis**.
- MARIANO, E. 2015. Predição da necessidade de fertilizante nitrogenado pela cana-de-açúcar e reações do nitrogênio orgânico e mineral dissolvidos em palha e solo de canaviais. **University of São Paulo, Thesis**.
- 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 of Agronomy**, 89:25-37.
- MENANDRO, L.M.S., CANTARELLA, H., FRANCO, H.C.J., PIMENTA, M.T.B., RABELO, S.C., SANCHES, G.M., CARVALHO, J.L.N., 2017. Comprehensive assessment of sugarcane straw: implications for biomass and bioenergy production. **Biofuels Bioproducts & Biorefining-Biofpr** 11(3):488-504.
- MOREIRA, L.A. 2017. Ureia estabilizada na adubação nitrogenada de cana-de-açúcar. **University of São Paulo, Dissertetion**.
- MULVANEY, R.L., KHAN, S.A., HOEFT, R.G., BROWN, H.M. 2001. A soil organic nitrogen fraction that reduces the need for nitrogen fertilization. **Soil Sci Soc Am J** 65:1164-1172.
- MULVANEY, R.L., KHAN, S.A., ELLSWORTH, T.R. 2006. Need for a soil-based approach in managing nitrogen fertilizers for profitable corn production. **Soil Sci Soc Am J** 70:172-182.
- ORLANDO FILHO, J.; RODELLA. A.A., BELTRAME J.Á.; LAVORENTI, N.A. 1999. Doses, fontes e formas de aplicação de nitrogênio em cana-de-açúcar. **STAB Açúcar Álcool e Subprodutos** 17:39–41
- 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. **Biol Fert Soils** 49:893–904.
- CORWIN, D.L.; LESCH, S.M. 2005. Apparent soil electrical conductivity measurements in agriculture. **Computers and Electronics in Agriculture** 46:11-43

- PENATTI, C.P.; ARAÚJO, J.V.; FORTI, J.A.; RIBEIRO, R. 2001 Doses de vinhaça e nitrogênio aplicadas em cana-soca durante quatro safras em solo LV—Usina São José da Estiva. **STAB-Açúcar Álcool e Subprodutos** 19:38–41
- PRADO, R.M.; PANCELLI, M. 2008. Resposta de soqueiras de cana-de-açúcar em sistema de colheita sem queima à aplicação de nitrogênio. **Bragantia** 67:951–959.
- RAIJ, B. VAN., CANTARELLA, H., QUAGGIO, J.A., FURLANI, A.M.C., 1997. Recomendações de adubação e calagem para o Estado de São Paulo. **Campinas. Instituto Agrônomo; Fundação IAC., Campinas.**
- ROSSETO, R.; DIAS, F.L.F.; LANDELL, M.G.A.; CANTARELLA, H.; TAVARES, S.; VITTI, A.C.; PERECIN, D. 2010. N and K fertilisation of sugarcane ratoons harvested without burning. **Proc. Int. Soc. Sugar Cane Technol** 27:1-8.
- SANCHES, G.M.; PAULA, M.T.N.; DUFT, D.G.; MAGALHAES, P.S.G.; FRANCO, H.C.J. 2019a. Precision production environments for sugarcane fields. **Scientia Agricola** 76(1), 10-17.
- SANCHES, G.M.; FRANCO, H.C.J.; MAGALHÃES, P.S.G. (2019b). 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. Cultura 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 Agrônomo.** p.237-239
- 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, K.A.; KITCHEN, N.R.; WIEBOLD, W.J.; BATCHELOR, W.D.; BOLLERO, G.A., BULLOCK, D.G.; et al. 2005. Relating apparent electrical conductivity to soil properties across the north-central USA. **Computers and Electronics in Agriculture**, 46(1–3):263–283.
- THORBURN, P.J.; BIGGS, J.S.; PALMER, J.; MEIER, E.A.; VERBURG, K.; SKOCAJ, D.M. 2017. Prioritizing crop management to increase nitrogen use efficiency in Australian sugarcane crops. **Front. Plant Sci.** 8:1504.
- VIEIRA, M.X.; TRIVELIN, P.C.O.; FRANCO, H.C.J.; OTTO, R.; FARONI, C.E. 2010. Ammonium chloride as nitrogen source in sugarcane harvested without burning. **R Bras Ci Solo** 34:1165–1174.
- VITTI, A.C.; TRIVELIN, P.C.O.; GAVA, G.J.C.; FRANCO, H.C.J.; BOLOGNA, I.R.; FARONI, C.E. 2007. Produtividade da cana-de-açúcar relacionada à localização de adubos nitrogenados aplicados sobre os resíduos culturais em canavial sem queima. **R Bras Ci Solo** 31:491–498.
- WONG, M.T.F.; ASSENG, S. 2006. Determining the causes of spatial and temporal variability of wheat yields at sub-field scale using a new method of upscaling a crop model. **Plant Soil** 283:203–215
- ZHU, X.; BURGER, M.; DOANE, T.A.; HORWATH, W.R. 2013. Ammonia oxidation pathways and nitrifier denitrification are significant sources of N<sub>2</sub>O and NO under low oxygen availability. **Proceedings of National Academy of Sciences of the United States of America** 110(16):6328-6333

# A VARIABILIDADE ESPACIAL DA VAZÃO DE GOTEJADORES AFETA A PERFORMANCE DA IRRIGAÇÃO LOCALIZADA PARA O CULTIVO DE VIDEIRAS VINÍFERAS

Larissa Godarelli Farinassi<sup>1</sup>; Bruno Ricardo Silva Costa<sup>2</sup>; Luis Henrique Basso<sup>3</sup>

<sup>1</sup>Engº Agrônoma, Doutoranda em Agronomia (Irrigação e Drenagem) - Departamento de Engenharia Rural e Socioeconomia, FCA, UNESP, Botucatu - SP. larissa\_godarelli@hotmail.com / (17) 9 9777-8615; <sup>2</sup>Engº Agrônomo, Doutor em Agronomia (Irrigação e Drenagem) - FCA, UNESP, Botucatu - SP; <sup>3</sup>Engº Agrônomo, Pesquisador - Embrapa Instrumentação, São Carlos - SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** O desempenho de um sistema de irrigação por gotejamento instalado em um vinhedo comercial foi avaliado conforme medidas da vazão dos emissores ( $L h^{-1}$ ) e cálculo dos coeficientes de uniformidade de distribuição (CUD, %) e de Christiansen (CUC, %), além da eficiência de aplicação (Ea, %). Cento e vinte pontos de coleta foram distribuídos ao longo da área para fins de caracterização da variabilidade espacial da vazão dos gotejadores por meio de análise geoestatística, seguida da predição espacial por krigagem. O sistema de irrigação avaliado apresentou uniformidade adequada, dada a classificação dos valores do CUD (89,41%, “bom”) e CUC (93,64%, “excelente”). Entretanto, a Ea (80,47%) apresentou-se abaixo dos valores de referência para sistema de irrigação localizada (90 - 95%). A variabilidade espacial da vazão dos emissores foi identificada e duas zonas homogêneas (ZH) foram delimitadas no vinhedo, as quais apresentaram diferença significativa entre si quanto a mediana da vazão precipitada pelos emissores. Como efeito, estimou-se que a irrigação total necessária (lâmina bruta) aplicada no decorrer de dois ciclos de produção da videira foi variável de acordo com cada zona delimitada no vinhedo.

**PALAVRAS-CHAVE:** Uniformidade de distribuição de água; Variabilidade espacial; Vitivinicultura

## THE SPATIAL VARIABILITY OF TRICKLE IRRIGATION EMITTERS FLOW RATE AFFECTS THE IRRIGATION PERFORMANCE FOR WINEGROWING

**ABSTRACT:** We evaluated the performance of a trickle irrigation system placed in a commercial vineyard through the measurements of the emitters flow rate and the calculation of the uniformity of water distribution coefficient (CUC, %), the Christiansen uniformity coefficient (CUC, %), and the application efficiency (Ea, %). One hundred and twenty sampling points were located towards the field to looking for the spatial variability in emitters flow rate by geostatistics and spatial prediction by kriging. The irrigation system had an appropriate uniformity according to the CUD (89.41%, “good”) and CUC (93.64%, “excellent”) results. However, the Ea (80.47%) did not meet the minimum standards for localized irrigation systems (90 - 95%). A spatial variability in emitters flow rate was found and two homogeneous zones (ZH) with significant differences between them were delimited. Therefore, a divergence in the gross irrigation depth applied across the vineyard throughout two consecutive growing seasons was predicted according to the emitters flow rate zoning.

**KEYWORDS:** Uniformity of water distribution; Spatial variability; Vitiviniculture

**INTRODUÇÃO:** Segundo Bernardo et al. (2009) os sistemas de irrigação localizada devem ser utilizados para o suprimento das necessidades hídricas de culturas de alto retorno econômico, em razão do seu maior custo por unidade de área. Dentre essas, destaca-se o cultivo de variedades de videiras para elaboração de vinhos finos, ou vitivinicultura, atividade que se desenvolve em regiões distintas do mundo, mesmo em locais que apresentam escassez hídrica natural e que demandam um sistema de irrigação capaz proporcionar uma maior eficiência do uso da água. Assim, no dimensionamento e manejo de sistemas de irrigação localizada, faz-se necessário a manutenção de sua máxima eficiência, de forma a proporcionar o maior controle possível sobre a lâmina de água aplicada. Neste sentido, a performance dos sistemas localizados tem sido comumente avaliada por meio de indicadores, calculados a partir de testes de uniformidade de distribuição de água,

conforme a coleta do volume de água precipitado por emissores ao longo das linhas laterais distribuídas longitudinalmente nas fileiras de plantio. Neste sentido, os estudos de caso publicados na literatura sobre o tópico preocupam-se, majoritariamente, em avaliar o desempenho dos sistemas de irrigação localizada por meio do cálculo dos coeficientes de uniformidade de distribuição ou CUC (Criddle et al., 1956) e de Christiansen ou CUD (Christiansen, 1942). Entretanto, o teste de uniformidade oportuniza uma avaliação da possível variabilidade espacial do volume de água aplicado pelos emissores por toda a extensão das áreas irrigadas. Essa abordagem é possível graças ao desenvolvimento de técnicas associadas ao conceito de agricultura de precisão, em especial o georrefenciamento de amostras no campo e a adoção dos métodos de análise geoestatística, que culminam na predição e representação espacial de variáveis de interesse, que neste caso é a vazão dos emissores de irrigação localizada não compensastes. Desta forma, o presente estudo teve como objetivo avaliar a performance de um sistema de gotejamento por meio do cálculo de coeficientes de uniformidade de distribuição e da eficiência de aplicação de água, além de caracterizar a variabilidade espacial da vazão dos emissores em um vinhedo irrigado, de modo a contabilizar as possíveis implicações desta sobre a irrigação total necessária aplicada no decorrer do ciclo de produção das videiras.

**MATERIAIS E MÉTODOS:** O teste de uniformidade de distribuição de água foi realizado em um sistema de irrigação por gotejamento instalado em um vinhedo comercial de 1,1 ha, implantado com a cultivar Syrah (*Vitis vinifera* L.) e localizado nas coordenadas 21°17'24,53" S, 47°50'46,83" O, a 730 m de altitude. O espaçamento adotado no vinhedo foi de 1,0 x 2,8 m entre plantas e fileiras, respectivamente. Em cada fileira de plantas foi disposta uma linha lateral, suspensa por um fio de arame a uma altura de 0,5 m do solo, contendo um emissor por planta, com vazão de projeto correspondente a 4,0 L h<sup>-1</sup> e pressão de serviço de 100 kPa. Cento e vinte pontos de coleta do volume de água precipitado pelos emissores foram dispostos ao longo das 24 linhas laterais instaladas no vinhedo (Figura 1A). Neste procedimento foram utilizadas provetas graduadas (mL) e, considerando-se um intervalo de tempo determinado (30 s), as medidas de volume foram posteriormente convertidas em unidade de vazão (L h<sup>-1</sup>). A partir desses resultados, calculou-se o coeficiente de uniformidade de distribuição (CUD, %) e o coeficiente de uniformidade de Christiansen (CUC, %), bem como a eficiência de aplicação (Ea, %), a partir das equações 1, 2 e 3, nesta ordem. A classificação dos valores de CUD e CUC foi definida segundo Mantovani (2001) e Frizzone et al. (2012).

$$CUD = X_{25} / X? \quad (1)$$

$$CUC = 100[1 - (\sum |X_i - X?| / n X?)] \quad (2)$$

$$Ea = 0,9 CUD \quad (3)$$

onde: X<sub>25</sub>: média das 25% menores vazões dentre todos os emissores avaliados (L h<sup>-1</sup>), X?: média das vazões de todos os emissores avaliados (L h<sup>-1</sup>), X<sub>i</sub>: vazão do i-ésimo emissor (L h<sup>-1</sup>), n: número total de emissores avaliados.

Uma vez que os pontos de coleta apresentavam coordenadas previamente conhecidas, definidas no plano cartesiano (eixo x, y) em função da localização das plantas, foi realizada a análise da dependência espacial da vazão distribuída ao longo do vinhedo por meio de análise geoestatística seguida da predição espacial para locais não amostrados. Ambas as etapas mencionadas foram realizadas utilizando-se o *software* Vesper (*Variogram Estimation and Spatial Prediction plus Error*) versão 1.6 (Minasny et al., 2005). Inicialmente, foi feito o ajuste de semivariogramas teóricos (isotrópicos), considerando-se os modelos esférico (equações 4 e 5), exponencial (equação 6) e gaussiano (equação 7) para esta finalidade. A escolha do melhor modelo ajustado se deu pelo exame do menor valor da raiz quadrada do erro quadrático médio (RMSE) produzido por cada modelo, definida segundo a equação 8. Todas as funções a seguir estão descritas em Grego e Oliveria (2015).

$$\gamma(h) = C_0 + C_1[3/2(h/a) - 1/2(h/a)^3], \text{ para: } 0 < h < a \quad (4)$$

$$\gamma(h) = C_0 + C_1, \text{ para: } h > a \quad (5)$$

$$\gamma(h) = C_0 + C_1[1 - \exp(-3 h/a)], \text{ para: } 0 < h < a \quad (6)$$

$$\gamma(h) = C_0 + C_1[1 - \exp(-3 (h/a)^2)], \text{ para: } 0 < h < a \quad (7)$$

$$RMSE = (1/N)(\sum SQDP)^{-2} \quad (8)$$

onde:  $\gamma(h)$ : valor da semivariância para o modelo ajustado, C0: efeito pepita; C1: patamar; a: alcance; h: distância e d: máxima distância na qual o semivariograma é definido, N: contagem do número de pares, SQPD: soma de quadrado dos desvios ponderados.

Na sequência, a estimativa dos valores de vazão foi realizada por método de krigagem ordinária. Conforme os limites definidos pelo contorno do vinhedo, foi gerada uma grade regular para interpolação assumindo-se uma resolução espacial de 0,50 m e adotou-se o método de krigagem em blocos, com dimensões espaciais de 5 x 5 m, para fins de predição espacial da vazão. Os resultados interpolados foram então classificados em um número predeterminado de dois níveis para fins de delimitação de zonas homogêneas (ZH) ao longo do vinhedo, segundo o método de quebras naturais ou otimização de Jenks. A classificação mencionada foi realizada utilizando-se a linguagem de programação R versão 3.6.2 e a função específica “getJenksBreaks”, contida na biblioteca BAMMtools (Rabosky et al., 2014).

Após a delimitação das ZH, os valores da vazão coletada nos pontos localizados em cada uma delas compuseram as amostras pertencentes a dois grupos independentes, que foram então comparados entre si por meio do teste não paramétrico da soma dos postos de Wilcoxon (ou Teste U de Mann-Whitney), admitindo-se um nível de significância de 5% ( $\alpha = 0,05$ ). O tamanho do efeito para o teste em questão foi calculado a partir da estatística A de Vargha e Delaney, o qual foi classificado como “pequeno” ( $0.56 < A < 0.64$ ), “moderado” ( $0.64 < A < 0.71$ ), ou “grande” ( $A > 0.71$ ) (Vargha e Delaney, 2000). Destaca-se que os valores de referência para a classificação de A foram arredondados para duas casas decimais.

Por fim, assumindo-se um turno de rega diário, foi realizada uma simulação da irrigação total necessária a ser aplicada em cada ZH ao longo de dois ciclos consecutivos de produção da videira (2020 e 2021). Essa estimativa foi realizada a partir de um tempo de irrigação em comum para toda a área (TI, em h), (equação 11) calculado a partir da vazão do projeto e a Ea obtida após o teste de uniformidade. Também foram consideradas as datas de poda e colheita realizadas no vinhedo, as fases fenológicas registradas e as condições climáticas locais, desconsiderando-se a precipitação pluviométrica no período.

A quantidade de água necessária, ou lâmina líquida, foi determinada a partir de valores diários da evapotranspiração da cultura ( $ET_c$ , mm dia<sup>-1</sup>). A  $ET_c$  foi calculada pelo produto entre a evapotranspiração de referência ( $ET_o$ , mm dia<sup>-1</sup>), estimada segundo o método de Penman-Monteith FAO (Allen et al., 1998) utilizando-se o *software* SMAI 2.0 (Feitosa et al., 2014), e o coeficiente de cultivo ( $k_c$ , adimensional) referente a um determinado intervalo entre estádios fenológicos. Os dados utilizados para determinação da  $ET_o$  foram provenientes da estação agrometeorológica localizada no município de Pradópolis - SP, pertencente ao INMET (Instituto Nacional de Meteorologia). Neste sentido, foram adotados os seguintes valores de  $k_c$ , utilizados pela vinícola: 0,3 (entre a poda e o início da floração), 0,7 (entre o início da floração e o início da maturação) e 0,4 (entre o início da maturação e a colheita). Na sequência, foi considerado um fator de ajuste ( $K_L$ ) (Keller e Bliesner, 1990) para o cálculo da evapotranspiração média para irrigação localizada ( $ET_L$ , mm dia<sup>-1</sup>) a partir dos valores de  $ET_c$ , conforme descrito pelas equações 9 e 10.

$$ET_L = ET_c K_L \quad (9)$$

$$K_L = 0,1 (P)^{-2} \quad (10)$$

onde: P: percentagem de área molhada (28,2%)

Assim, a lâmina bruta (LB, mm dia<sup>-1</sup>) foi determinada de acordo com a equação 12, a partir da razão entre os valores diários estimados de  $ET_L$  e a Ea. Substituindo a equação 12 na equação 11, têm-se o valor de LB em cada ZH calculado a partir de um dado TI, adotando-se a mediana dos valores de vazão dos emissores em cada sub-região para este cálculo (equação 13).

$$TI = (ET_L e_1 e_2)/(Ea N q) \quad (11)$$

$$LB = ET_L/Ea \quad (12)$$

$$LB = (TI e_1 e_2)/(N q) \quad (13)$$

onde:  $e_1$  e  $e_2$ : espaçamento entre plantas e fileiras (m), respectivamente; N: número de emissores por planta; q: vazão do emissor ( $L h^{-1}$ ).

De posse dos valores simulados de LB, calculou-se a função distribuição acumulada equivalente a irrigação total aplicada em cada ZH, que foram comparadas entre si por meio do teste de Kolmogorov Smirnov, adotando-se um nível de significância de 5% ( $\alpha = 0,05$ ). Todos os testes estatísticos mencionados anteriormente foram realizados por meio da linguagem de programação R versão 3.6.2.

**RESULTADOS E DISCUSSÃO:** O sistema de irrigação por gotejamento avaliado apresentou desempenho satisfatório, conforme a classificação dos indicadores de uniformidade de distribuição de água considerados. Os valores do CUD e CUC foram iguais a 89,41 e 93,64%, respectivamente, sendo classificados como “bom” e “excelente”. Entretanto, a  $E_a$  (80,47%) encontrou-se abaixo dos valores recomendados para sistemas de irrigação localizada (90-95%) (Mantovani et al., 2009).

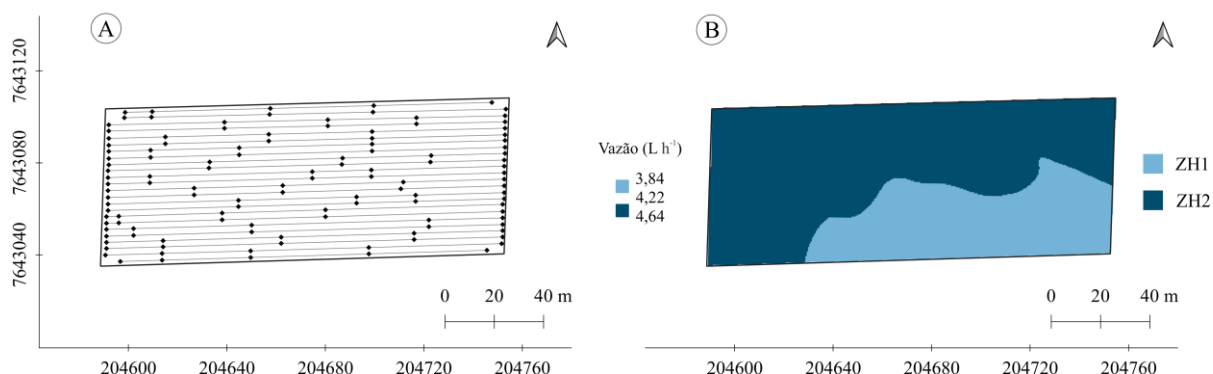
Considerando-se a vazão dos emissores como uma variável regionalizada, a sua variabilidade espacial foi identificada a partir do teste de uniformidade de distribuição. Na análise da dependência espacial desta variável, adotou-se o modelo esférico para o melhor ajuste do semivariograma teórico, em razão do RMSE produzido por este, que foi reduzido em comparação àquele correspondente aos demais modelos examinados (Tabela 1). A partir da predição espacial da vazão, foi possível delimitar duas ZH, em conformidade com a classificação dos valores interpolados (Figura 1B). A área equivalente a ZH1 e ZH2 foi de 0,36 e 0,75 ha, respectivamente. Após essa distinção, o teste das somas de postos de Wilcoxon detectou uma diferença significativa entre as sub-regiões do vinhedo quanto a vazão dos emissores situados em cada uma destas ( $W = 236,50$ ,  $p\text{-valor} = 2,39 \cdot 10^{-12}$ ). Assim, a mediana da vazão dos gotejadores localizados na ZH1 foi inferior àquela referente aos emissores localizados na ZH2 (Tabela 2). A significância prática dessa diferença foi classificada como “grande”, segundo a análise do tamanho do efeito ( $A = 0,084$ ).

TABELA 1. Parâmetros dos semivariogramas ajustados para análise da dependência espacial da vazão dos emissores ao longo do vinhedo. **The semivariogram parameters fitted to assesses the spatial dependence of emitters flow rate across the vineyard.**

Modelo	$C_0$	$C_1$	a	RMSE
Esférico	$8,198 \cdot 10^{-2}$	$6,137 \cdot 10^{-2}$	48,68	$6,862 \cdot 10^{-3}$
Exponencial	$6,719 \cdot 10^{-2}$	$7,939 \cdot 10^{-2}$	18,29	$7,085 \cdot 10^{-3}$
Gaussiano	$9,160 \cdot 10^{-2}$	$5,182 \cdot 10^{-2}$	23,80	$6,871 \cdot 10^{-3}$

$C_0$ : efeito pepita;  $C_1$ : patamar; a: alcance; RMSE: raiz quadrada do erro quadrático médio.

FIGURA 1. Pontos de coleta e zonas homogêneas (ZH) da vazão dos emissores ao longo do vinhedo. **Sampling points and homogeneous zones of emitters flow rate across the vineyard.**



Sistema de referência de coordenadas: WGS 84/UTM Zona 23S EPSG: 32723


TABELA 2. Estatística descritiva correspondente a vazão dos emissores localizados em cada zona homogênea (ZH). **Statistics of the emitter flow rate at each homogeneous zone (ZH).**

Zona	n	Média	Desvio	Mín.	Q1	Q2	Q3	Máx.
ZH1	32	3,98	0,21	3,48	3,84	3,96 b	4,08	4,32
ZH2	88	4,46	0,35	3,48	4,32	4,44 a	4,56	6,36

n: número de observações; Mín: valor mínimo; Q1: primeiro quartil; Q2: segundo quartil (mediana); Q3: terceiro quartil; Máx: valor máximo. Medianas seguidas de mesma letra diferem entre si, conforme o teste U da soma de postos de Wilcoxon, ao nível de significância de 5% ( $\alpha = 0,05$ ).

Proporcionalmente, foi observada uma diferença significativa ao se comparar as funções densidade de probabilidade acumulada quanto a lâmina bruta aplicada nas diferentes sub-regiões do vinhedo, segundo a simulação da demanda hídrica local ao longo de ambos os ciclos de produção da videira (Figura 2). Assim, de acordo com o teste de Kolmogorov-Smirnov, foi possível rejeitar a hipótese nula de que as amostras de vazão correspondentes as zonas 1 e 2 provinham de uma mesma distribuição, nas comparações feitas no ciclo de 2020 ( $D = 0,16$ ,  $p$ -valor =  $1,68 \cdot 10^{-2}$ ) e 2021 ( $D = 0,19$ ,  $p$ -valor =  $4,67 \cdot 10^{-3}$ ).

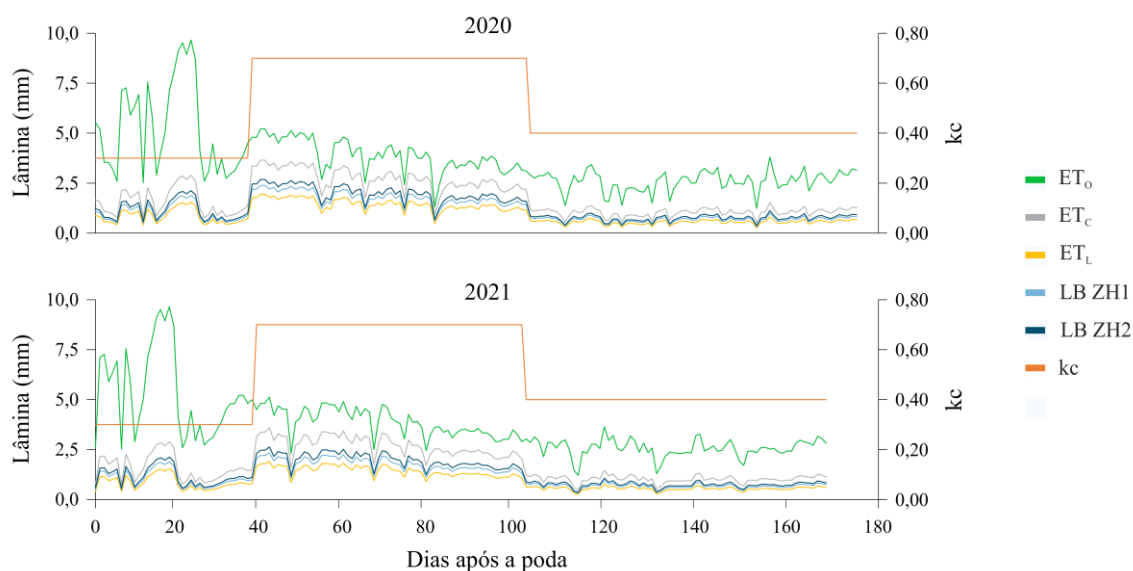
FIGURA 2. Funções densidade de probabilidade acumulada correspondentes a lâmina bruta de irrigação simulada para cada zona homogênea (ZH) durante dois ciclos de produção da videira. **Empirical cumulative distribution function for the simulated gross irrigation depth for each homogeneous zone (ZH) throughout two grapevine growing seasons.**



Logo, a ZH1 apresentou uma maior frequência de valores inferiores da irrigação total necessária simulada, uma vez que a sua curva da função distribuição de probabilidade acumulada foi deslocada para a esquerda em comparação àquela correspondentes a ZH2 (Figura 3). Desta maneira, pressupôs-se que a quantidade de água a ser aplicada na ZH1 foi inferior àquela aplicada na ZH2, no decurso de ambos os ciclos de produção da videira. Assim, a LB estimada durante o ciclo de produção de 2020 na ZH1 e ZH2, nesta ordem, foi igual a 202,66 e 227,73 mm, enquanto no ano seguinte, esta foi equivalente a 195,52 e 219,22 mm, respectivamente. Convertendo os valores de LB em volume de água aplicada por planta e, a partir da quantidade de plantas em cada ZH, têm-se os seguintes valores para água total aplicada por ciclo na ZH1 e ZH2, respectivamente: 745,56 e 1630,02 m<sup>3</sup> (2020); 720,25 e 1572,58 m<sup>3</sup> (2021). Logo, a diferença no volume de água por planta em cada ZH foi de 68,78 e 66,36 L nos ciclos de produção de 2020 e 2021, respectivamente, a qual representou uma variação de 12,12% na irrigação aplicada na ZH2 em relação a ZH1. A série temporal das lâminas simuladas em ambos os ciclos de produção foi apresentada na Figura 3.

FIGURA 3. Variação temporal da evapotranspiração e da lâmina de irrigação estimada no decorrer dos ciclos de produção da videira. **Temporal variation of evapotranspiration and irrigation water depth estimated throughout the grapevine growing seasons.**





Para fins de adoção de práticas de manejo sítio específico no cultivo de videiras viníferas, conforme a abordagem denominada vitivinicultura de precisão, torna-se imprescindível a detecção da variabilidade espacial dos vinhedos, uma vez que as condições ambientais circundantes influenciam na qualidade e composição das bagas e determinam o *terroir* dos vinhos produzidos. Assim, a detecção da variabilidade espacial em vinhedos têm sido caracterizada especialmente para orientar a colheita e vinificação seletiva (Oldoni et al., 2021). Contudo, os resultados deste estudo demonstram que a influência antrópica sobre o cultivo de videiras viníferas, em termos do manejo da irrigação, também pode promover uma variabilidade extrínseca as condições naturais dos vinhedos.

**CONCLUSÃO:** Apesar dos resultados adequados quanto a performance do sistema de irrigação localizada, foi possível identificar a variabilidade espacial da Agricultura de vazão dos gotejadores ao longo do vinhedo em estudo. A análise dos padrões de distribuição espacial da vazão implicou na delimitação de zonas homogêneas quanto a essa variável e, conseqüentemente, culminou na diferenciação da quantidade de água aplicada em regiões distintas de um único vinhedo ao longo do ciclo de produção da videira.

#### AGRADECIMENTOS:

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão de bolsas de estudos. À FAPESP, pelo apoio financeiro. À Rede de Precisão da Embrapa, pelo suporte técnico. A Vinícola Terras Altas (Ribeirão Preto - SP) pela concessão da área de estudo

#### REFERÊNCIAS

- ALLEN, R.G.; PEREIRA, L.S.; RAES, D.; SMITH, M. **Crop evapotranspiration: guidelines for computing crop water requirements. Irrigation and Drainage Paper, 56.** Rome: FAO, 1998, 300 p.
- BERNARDO, S.; SOARES, A.A.; MANTOVANI, E.C. Irrigação localizada (gotejamento e microaspersão). In: \_\_\_\_\_. **Manual de irrigação.** Viçosa: Universidade Federal de Viçosa, 2009, p. 483-548.
- CHRISTIANSEN, J. E. **Irrigation by sprinkler.** Berkeley: California Agricultural Station, 1942. 212p.
- CRIDDLE, W.D.; DAVIS, S.; PAIR, C.H.; SHOCKELEY, D.G. **Methods for evaluating irrigation systems.** Washington: SCS-USDA, 1956. 24p.

FEITOSA, D.G.; MARIANO, J.C.Q.; HERNANDEZ, F.B.T.; SANTOS, G.O.; TEIXEIRA, A.H.C. Software SMAI 2.0 para estimativa da evapotranspiração de referência diária e horária. In: CONIRD – CONGRESSO NACIONAL DE IRRIGAÇÃO E DRENAGEM, XXIV, 2014, Brasília – DF. **Anais...** Brasília: ABID – Associação Brasileira de Irrigação e Drenagem, 2014.

FRIZZONE, J.A.; FREITAS, P.D.; REZENDE, R.; FARIA, M.D. **Microirrigação: gotejamento e microaspersão**. Maringá: Eduem, 2012.

GREGO, C.R.; OLIVEIRA, R.O. Conceitos básicos da geoestatística. In: OLIVEIRA, R.O.; GREGO, C.R., BRANDÃO, Z.N. (Ed). **Geoestatística aplicada na Agricultura de Precisão utilizando o Vesper**. Brasília: Embrapa, 2015, p.41-62.

KELLER, J.; BLIESNER, R.D. **Sprinkle and trickle irrigation**. New York: Van Nostrand Reinold, 1990, 652 p.

MANTOVANI, E.C. **Avalia: programa de avaliação da irrigação por aspersão e localizada**. Viçosa, MG: UFV, 2001.

MINASNY, B.; MCBRATNEY, A.B.; WHELAN, B.M. **Vesper version 1.62**. Sydney: Australian Centre for Precision Agriculture. 2005.

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, p. 1-10, 2021.

RABOSKY, D.; GRUNDLER, M.; ANDERSON, C.; TITLE, P.; SHI, J.; BROWN, J.; HUANG H.; LARSON, J. BAMMtools: an R package for the analysis of evolutionary dynamics on phylogenetic trees. **Methods in Ecology and Evolution**, v.5, p.701-707, 2014.

# CLASSIFICAÇÃO DE PRESENÇA-AUSÊNCIA DE PLANTAS DANINHAS DE FOLHA LARGA EM PASTAGEM POR SENSORIAMENTO REMOTO

Cenneya Lopes Martins<sup>1</sup>; Agda Loureiro Gonçalves Oliveira<sup>2</sup>; Joaquim Pedro de Lima<sup>3</sup>; Henrique Oldoni<sup>4</sup>; Lucas Rios do Amaral<sup>5</sup>

<sup>1</sup>Eng<sup>a</sup>. Agrônoma, Estudante de doutorado - Programa de Pós-Graduação da Faculdade de Engenharia Agrícola, FEAGRI, UNICAMP, Campinas, SP.. cenneya.martins@feagri.unicamp.br / (11) 9 9424-9129;

<sup>2</sup>Eng<sup>a</sup>. Agrícola, Estudante de doutorado - Programa de Pós-Graduação da Faculdade de Engenharia Agrícola, FEAGRI, UNICAMP, Campinas, SP; <sup>3</sup>Eng<sup>o</sup>. Agrícola, Estudante de doutorado - Programa de Pós-Graduação da Faculdade de Engenharia Agrícola, FEAGRI, UNICAMP, Campinas, SP; <sup>4</sup>Eng<sup>o</sup>. Agrícola, Pós-doutorando - Núcleo Interdisciplinar de Planejamento Energético, NIPE, UNICAMP, Campinas, SP.;

<sup>5</sup>Eng<sup>o</sup>. Agrônomo, Professor, doutor - Programa de Pós-Graduação da Faculdade de Engenharia Agrícola, FEAGRI, UNICAMP, Campinas, SP.

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** As plantas daninhas podem reduzir a produtividade das culturas agrícolas. Além disso, algumas espécies possuem substâncias tóxicas para o gado. Assim, o manejo inadequado dessas plantas pode gerar prejuízos à produção agropecuária. Desse modo, a constatação de presença dessas plantas ao longo da área de pastagem é necessária. Porém, o mapeamento de plantas daninhas em cultura já instalada é um desafio. Uma alternativa para viabilizar essa abordagem seria a utilização de variáveis auxiliares oriundas do sensoriamento e de coletas realizadas previamente no campo. Nesse sentido, o objetivo foi testar se o uso de dados de solo, relevo e de sensoriamento remoto em um modelo de classificação Random Forest permite a detecção e mapeamento de presença-ausência de plantas daninhas de folha larga em área de pastagem. O experimento foi conduzido em uma área de 200 hectares, no município de Caiuá, SP. As plantas daninhas foram identificadas e quantificadas em 100 pontos aleatórios georreferenciados ao longo da área. Nesses mesmos pontos, variáveis de solo, relevo e sensoriamento remoto foram colocados para serem empregadas na modelagem: teor de argila, CTC, altitude da área, condutividade elétrica aparente do solo, declividade do terreno e os índices de vegetação SAVI, ARVI, EVI2, CIgreen, SR, NDVI, NGRDI, GNDVI, gerados a partir de imagem da PlanetScope. A predição foi realizada pelo modelo de classificação Random Forest. Na matriz de confusão, observamos que o modelo acertou 100% das predições de ausência de plantas daninhas (Falso positivo = 0). Por outro lado, o modelo errou na identificação de ausência de plantas daninhas em quatro pontos amostrais (Falso negativo = 4). Entre as métricas para avaliação do modelo, obtivemos uma acurácia de 0,88, precisão 1, Recall 0,73 e F1 Score 0,84. Logo, o modelo foi adequado para prever a presença-ausência de plantas daninhas de folha larga ao longo da pastagem.

**PALAVRAS-CHAVE:** Manejo de Pantas daninhas; Aprendizado de máquinas; Sistema de Integração Lavoura-Pecuária

## CLASSIFICATION PRESENCE-ABSENCE OF BROAD-LEAVED WEEDS IN PASTURE BY REMOTE SENSING

**ABSTRACT:** Weeds can reduce the productivity of agricultural crops. In addition, some species have toxic substances to livestock. Thus, the inadequate management of these plants can generate losses to livestock production. Thus, the verification of the presence of these plants along the pasture area is necessary. However, the mapping of weeds in crops already installed is a challenge. An alternative to make this approach viable would be the use of auxiliary variables derived from remote sensing and collections previously carried out in the field. In this sense, the objective was to test whether the use of soil information and remote sensing data in a Random Forest classification model allows the detection and presence-absence mapping of broad-leaved weeds in a pasture area. The experiment was conducted in an area of ??200 hectares, in the municipality of Caiuá, SP. Weeds were identified and quantified at 100 random georeferenced points along the area. In these same points, soil, relief and remote sensing variables were collocated to be employed in the modeling: clay content, CTC, altitude of the area, apparent electrical conductivity of the soil, terrain slope and the vegetation

índices SAVI, ARVI, EVI2, CIGreen, SR, NDVI, NGRDI, GNDVI, gerados a partir de imagens PlanetScope. A predição foi realizada por modelo de classificação Random Forest. Na matriz de confusão, observamos que o modelo acertou 100% das predições de ausência de ervas daninhas (Falso positivo = 0). Por outro lado, o modelo errou em identificar a ausência de ervas daninhas em quatro pontos amostrais (Falso negativo = 4). Entre as métricas de avaliação do modelo, obtemos uma precisão de 0,88, recall de 0,73 e F1 Score de 0,84. Portanto, o modelo é adequado para prever a presença ou ausência de ervas daninhas ao longo do pasto.

**KEYWORDS:** Weeds management; Machine Learning; Crop-Livestock Integration System

**INTRODUÇÃO:** As plantas daninhas competem com as culturas agrícolas, causando reduções na sua produtividade. Além disso, algumas espécies podem apresentar substâncias tóxicas para o gado (RATH et al., 2016; ISH et al., 2019; ALMEIDA JÚNIOR et al., 2021). Assim, quando não manejadas eficientemente, acarretam prejuízos indiretos e diretos na produção agropecuária.

Tradicionalmente o manejo de plantas daninhas é realizado em área total, com base na média de infestação. Porém, tais plantas se distribuem de forma heterogênea nas áreas de cultivo (NORDMEYER, 2006) e, frequentemente, de forma agregada ou em “reboleiras” (CHIBA et al., 2010). A distribuição das manchas de plantas daninhas nas áreas ocorre em função do banco de sementes do solo, dispersão, fatores edáficos e outros (REW e COUSENS, 2001; NORDMEYER, 2006; METCALFE et al., 2019).

A Agricultura de Precisão (AP) é um modo de gestão que visa mapear e tratar as variabilidades das lavouras, através do manejo localizado (MOLIN et al., 2015). Entretanto, as amostragens manuais de plantas daninhas para fins de tratamento localizado, são dispendiosas e pouco eficientes na identificação dos locais infestados em grandes áreas (REW e COUSENS, 2001). Embora sensores acoplados aos pulverizadores permitam a identificação e controle de plantas daninhas nas entrelinhas da cultura (PETEINATOS et al., 2014), em casos em que a cultura cubra totalmente o solo, como as pastagens, a identificação de plantas daninhas por meio dessas técnicas é um desafio (LÓPEZ-GRANADOS, 2010).

Tecnologias de Sensoriamento Remoto (SR) podem auxiliar na detecção remota das plantas daninhas. Sensores remotos são capazes de medir a radiação eletromagnética refletida pela vegetação, que é influenciada pelo conteúdo de pigmentos, estrutura foliar e conteúdo de água na planta (FORMAGGIO e SANCHES, 2017). Entretanto, a capacidade de um SR detectar com precisão plantas daninhas nas lavouras, depende de sua resolução espacial e espectral (LAMB e BROWN, 2001). Outros problemas para a detecção de daninhas em pós-emergência das culturas são os efeitos de fundo do solo (THORP e TIAN, 2004) e a semelhança das características espectrais das plantas daninhas e cultivadas (LAMB e BROWN, 2001).

Considerando as diferenças morfológicas das plantas daninhas monocotiledôneas e dicotiledôneas e o seu manejo, estas podem ser divididas em “folha estreita” e “folha larga”, respectivamente. Diferentemente das plantas daninhas de folha estreita, o dossel de plantas daninhas de folha larga dificilmente se assemelha às pastagens, e podem mais facilmente ser diferenciadas por SR. SOUZA et al. (2020) observaram diferenças espectrais entre cana-de-açúcar (gramínea) e plantas daninhas, marcadamente as dicotiledôneas. Assim, o objetivo deste trabalho foi testar se com a utilização de dados espectrais de SR e atributos do solo e terreno como variáveis auxiliares em modelo de aprendizado de máquina para classificação, é possível detectar a presença e ausência de plantas daninhas de folha larga em área de pastagem.

**MATERIAIS E MÉTODOS:** O estudo foi conduzido em uma área de 200 ha (Latitude 21°38'15” e Longitude 51°54'56”) sob manejo em sistema de integração lavoura-pecuária, com soja sucedida por pastagem, formada por braquiária e milheto, localizada no município de Caiuá-SP. A textura do solo foi classificada como arenosa, com valores médios de 95 g kg<sup>-1</sup> de argila, 102 g kg<sup>-1</sup> de silte e 803 g kg<sup>-1</sup> de areia na camada de 0,00 - 0,40 m.

No ano de 2019, 100 pontos georreferenciados foram alocados na área de modo aleatório, nos quais foram extraídos dados de 14 variáveis: argila e capacidade de troca catiônica (CTC) a partir de amostragem de solo na camada de 0 - 0,20 cm, altitude, condutividade elétrica aparente do solo, declividade, coordenadas geográficas e os seguintes índices de vegetação (IVs): SAVI, ARVI, EVI2, CIGreen, SR, NDVI, NGRDI, GNDVI (TABELA 1). Esses dados foram utilizados como variáveis preditoras. Os IVs foram calculados a

partir de imagem de SR da plataforma PlanetScope ortorretificadas por padrão, com as bandas espectrais vermelho, verde e azul na região visível, e uma banda na região do infravermelho próximo, resolução radiométrica de 12 bits, resolução espacial de 3 m e resolução temporal diária (SCCON GEOSPATIAL, 2019).

TABELA 1. Índices de Vegetação. **Vegetation indices.**

Índice de Vegetação	Nome	Fórmula	Referências
SAVI	<i>Soil Adjusted Vegetation</i>	$\frac{(NIR - RED)(1 + L)}{(NIR + RED) + L}$	HUETE (1988)
ARVI	<i>Atmospherically resistant vegetation index</i>	$\frac{(NIR - RB)}{(NIR + RB)}$	KAUFMAN e TANRE (1992)
EVI2	<i>Two-band enhanced vegetation index</i>	$\frac{2.5 NIR - RED}{NIR + 2.4 RED + 1}$	JIANG et al. (2008)
CIgreen	<i>Chlorophyll index -Green</i>	$\frac{NIR}{GREEN} - 1$	GITELSON et al. (2003, 2005)
SR	<i>Simple Ratio</i>	$\frac{NIR}{RED}$	JORDAN (1969)
NDVI	<i>Normalized difference vegetation index</i>	$\frac{NIR - RED}{NIR + RED}$	ROUSE et al. (1973)
NGRDI	<i>Normalized Green Red Difference Index</i>	$\frac{GREEN - RED}{GREEN + RED}$	TUCKER (1979)
GNDVI	<i>Green Normalized Difference Vegetation</i>	$\frac{NIR - GREEN}{NIR + GREEN}$	GITELSON et al. (1996)

\*Bandas espectrais: NIR = Infravermelho próximo; RED = Vermelho; GREEN = verde;

\*ARVI: RB = Red -  $\gamma$ (Red - Blue);

\*SAVI: L = fator de ajuste do índice.

Nos mesmos 100 pontos foram realizadas amostragens de plantas daninhas, quando a pastagem estava em pleno desenvolvimento (julho de 2019) e, a imagem de SR selecionada representou a data das amostragens (FIGURA 1). O levantamento de plantas daninhas na área foi realizado através do método quadrado inventário (1,0 m<sup>2</sup>: 1,0 x 1,0 m) lançado em cada ponto amostral. Para quantificação das plantas daninhas, a cada lançamento do quadrado inventário, as espécies emergidas encontradas dentro do quadrado foram contadas e identificadas. A presença e ausência de plantas daninhas de folha larga, variável meta, resultaram em uma coluna de dados binários (0 - ausência e 1- presença). As espécies de plantas daninhas de folha larga encontradas na área foram: *Macroptilium lathyroides* (angiquinho), *Crotalaria incanum* (crotalaria), *Sida* sp. (guanxuma), *Calopogonium muconoides* (calopogonium), *Macroptilium atropurpureum* (siratiro), *Senna occidentalis* (fedegoso), *Commelina benghalensis* (trapoeraba), *Macroptilium lathyroides* (feijão-de-rola), *Gompherna globosa* (amaranto globoso), *Desmodium tortuosum* (carrapicho beijo-de-boi), *Amaranthus deflexus* (caruru), *Physalis angulata* (juá de capote), *Alysicarpus vaginalis* (amendoinzinho-do-campo) e *Glycine max* (soja). É importante frisar que a trapoeraba frequentemente é classificada como sendo uma planta daninha de folha larga, pois apresenta características morfológicas que mais se assemelham a este grupo. Entretanto, a trapoeraba é uma monocotiledônea. Para fins de diferenciação na pastagem, julgamos interessante incluí-la como sendo planta folha larga neste trabalho. Os pontos amostrais continham manchas com quantidades de plantas daninhas de folha larga que variavam de 0 a 25 unidades de plantas das referidas espécies.

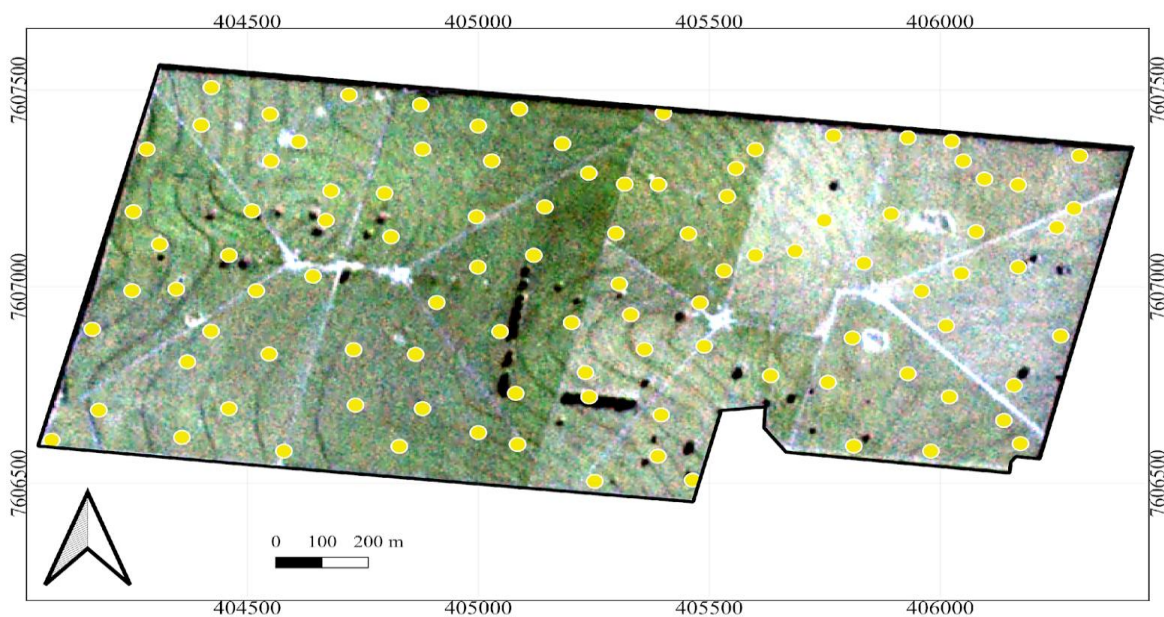


FIGURA 1. Área experimental, julho de 2019, indicando os locais dos pontos amostrais, Caiuá, SP. Imagem PlanetScope em composição de cores verdadeiras. **Experimental area, July 2019, Caiuá-SP, indicating the locations of the sampling points. PlanetScope image in true color rendering.**

Para evitar resultados enviesados, antes da modelagem realizamos um balanceamento de classes do tipo Random oversampling com uma super amostragem da classe 0. Nesse tipo de balanceamento, dados da classe minoritária são aleatoriamente selecionados e copiados (DOMINGUES et al., 2018). Antes do balanceamento, apenas 20% dos dados pertenciam à classe 0. Após o balanceamento, obtivemos 50% dos dados em cada classe. Ao igualar o número de observações das classes, o balanceamento garante que o conjunto total de dados represente o conjunto de treino. Os dados foram divididos aleatoriamente em 80% dos dados no conjunto treino e 20% no conjunto teste. No conjunto teste obtivemos 32 observações, destas, 17 sem plantas daninhas de folha larga e 15 com daninhas. Já o conjunto treino, com 124 observações, 61 sem plantas daninhas e 63 com plantas daninhas.

As predições de presença e ausência de plantas daninhas de folha larga foram realizadas por meio do modelo de classificação Random Forest, com o valor zero atribuído à ausência de daninhas e valor um (presença) atribuído quando ao menos uma planta de folha larga estava presente no ponto amostral. Para escolha do melhor modelo, foi utilizada uma otimização dos hiperparâmetros com número de árvores (testado de 100 a 3000 árvores), número de variáveis selecionadas a cada divisão (testado de 1 a 14), e número mínimo de terminações (testado de 2 a 30), sendo o melhor modelo com 785 árvores, 2 variáveis por divisão e 3 terminações. Toda a modelagem e predição foi realizada com o pacote mlr (BISCHL et al., 2016) do software R. As métricas utilizadas para avaliação do desempenho do modelo foram: Acurácia, Precisão, Recall e F1 Score, calculadas a partir dos dados da matriz de confusão para os dados de teste.

Para compreender a distribuição de plantas daninhas ao longo da área, realizamos a predição da probabilidade de ocorrência de plantas daninhas utilizando as covariáveis mais importantes: CIGreen, declividade, ARVI, altitude, SAVI, e GNDVI para o modelo (exceto coordenada X) e os melhores hiperparâmetros. Utilizamos o pacote ranger do R para elaboração do modelo e o pacote stats para predição da probabilidade de ocorrência da classe presença de plantas daninhas (HENGL et al., 2018).

**RESULTADOS E DISCUSSÃO:** A utilização de IVs gerados a partir de imagens PlanetScope juntamente com dados do terreno no modelo de classificação Random Forest, se mostrou adequada para a predição de presença e ausência de plantas daninhas de folha larga em área de pastagem. As variáveis mais importantes para o modelo foram: coordenada X, CIGreen, declividade, ARVI, altitude, SAVI e GNDVI.

Os IVs se destacam entre as principais contribuições do sensoriamento remoto. São combinações de duas ou mais bandas espectrais, projetados para destacar as propriedades da vegetação e permitir comparações espaciais e temporais de parâmetros como fotossíntese, IAF, biomassa e cobertura do dossel (HUETE et al., 2002). Nessa pesquisa, observa-se que todos os IVs importantes para determinar a presença de plantas daninhas em área de pastagem utilizam em sua fórmula matemática, a banda espectral do infravermelho próximo (NIR). O NIR apresenta relação com a estrutura interna das folhas e, nessa região, as folhas verdes saudáveis apresentam altos valores de reflectância. Na região visível, por outro lado, a reflectância da vegetação é baixa e tem relação com a absorção da radiação eletromagnética nas bandas do azul e vermelho pelos pigmentos das folhas para suas atividades fotossintéticas (FORMAGGIO e SANCHES, 2017). Entre os IVs mais importantes para a modelagem, o SAVI e ARVI utilizam além do NIR, a banda do vermelho, apresentando correções para influências do solo e atmosfera, respectivamente, e foram propostos como melhorias do NDVI (HUETE, 1988; KAUFMAN e TANRE., 1992), o que foi comprovado neste estudo, uma vez que esses índices foram selecionados pelo modelo em detrimento do NDVI. O CIGreen e o GNDVI utilizam a banda verde e foram propostos para estimativa de clorofila total (GITELSON et al., 1996; GITELSON et al., 2005). GITELSON et al. (2005), verificaram que o modelo CIGreen diferencia com precisão a clorofila entre espécies muito contrastantes, como entre as culturas de soja (folha larga) e milho (folha estreita), isso porque a soja possui folhas predominantemente horizontais enquanto no milho, a distribuição do ângulo foliar é mais hemisférica, além disso, a quantidade de clorofila na superfície adaxial das folhas de soja é em maior. A estrutura interna das folhas varia entre as espécies, assim, as diferenças de reflectância, geralmente, são maiores na região do infravermelho que no visível (FORMAGGIO e SANCHES, 2017). Com isso, a diferença estrutural entre as plantas daninhas de folha larga e folhas de pastagem (folha estreita) favoreceu o potencial dos IVs em diferenciar as espécies. Isso porque há maior diferença estrutural foliar entre espécies de monocotiledôneas e dicotiledôneas, quando comparada às espécies pertencentes ao mesmo grupo.

A declividade e a altitude apresentam relação com a variabilidade da textura e umidade dos solos (SANTOS et al., 2002; MURPHY et al., 2009; RAMOS et al., 2020). Interessante notar que as variáveis de solo não foram importantes para determinar a presença de plantas daninhas, diferentemente do relatado em algumas pesquisas (REW e COUSENS, 2001; METCALFE et al., 2019). As amostragens de argila foram obtidas de forma mais esparsa comparada às imagens de satélite que geraram os dados de declividade e altitude. Dessa forma, a variabilidade espacial dos dados de solo é melhor captada pelo sensor, conseqüentemente, essas variáveis possuem melhor capacidade preditiva. Isso demonstra que informações de simples obtenção de forma remota podem auxiliar no mapeamento de áreas potencialmente infestadas por plantas daninhas de interesse; neste caso, plantas de folha larga no meio da pastagem de braquiária e milheto. A não influência das variáveis do solo na localização das plantas daninhas de folha larga, verificada neste estudo, pode estar relacionada às variáveis selecionadas para utilização no modelo e à quantidade de espécies avaliadas conjuntamente; pois diferentes espécies de plantas daninhas podem ser mais ou menos influenciadas parâmetros do solo (PÄTZOLD et al., 2020).

Ao detalharmos os resultados da classificação por meio da matriz de confusão (TABELA 2), notamos que o falso positivo foi igual a 0, logo, o modelo acertou 100% das predições de presença de plantas daninhas. Isso significa que o modelo não erraria na predição de locais infestados e, por consequência, não levaria a decisão equivocada de aplicação de herbicidas em locais que não requerem controle, gerando custos desnecessários com aplicações desses defensivos. Por outro lado, o falso negativo indica que o modelo errou na identificação de ausência de plantas daninhas em quatro pontos amostrais, ou seja, inferiu que não havia plantas daninhas de folha larga, quando na verdade existiam. Nesse caso, esses locais ficariam sem o controle, mesmo necessitando-o, o que poderia acarretar na permanência de plantas daninhas como foco de infestação e em problemas no manejo da pastagem e gado, por exemplo, com uma alimentação prejudicada pela pastagem pouco desenvolvida ou até mesmo a ocorrência de intoxicação de animais, caso haja plantas daninhas tóxicas nesses pontos. Ainda assim, o número de acertos “verdadeiro positivo” foi considerável (acima de 60%) e, somado aos 100% de acertos quanto aos locais de presença de plantas daninhas, leva a um bom mapeamento das plantas daninhas para o controle da maioria dos locais infestados. Além disso, grandes locais identificados com ausência de plantas daninhas podem servir como pontos estratégicos para manter o rebanho em pastejo durante o controle dos demais locais da área.

TABELA 2. Matriz de confusão. VP – verdadeiro positivo, VN – verdadeiro negativo, FP – falso positivo e FN – falso negativo. **Confusion matrix. VP – true positive, VN – true negative, FP – false positive and FN – false negative.**



		Predito	
		Presença	Ausência
Observado	Presença	11 (VP)	4 (FN)
	Ausência	0 (FP)	17 (VN)

Com o cálculo das métricas para a avaliação do modelo, obtivemos uma acurácia de 0,88, precisão de 1, Recall de 0,73 e F1 Score de 0,84. A acurácia indica o percentual de acertos do modelo; a precisão 1 indica que tudo que foi predito como positivo, realmente havia plantas daninhas. O recall indica que de tudo o que o modelo previu como positivo, 73% estava correto e; o F-Score é uma média harmônica calculada com base na precisão e no recall (MARIANO, 2021), o que indica a confiabilidade da acurácia (0,84).

A partir das predições foi possível gerar um uma superfície de probabilidade de ocorrência de plantas daninhas na área de estudo (FIGURA 2). Os pontos contendo a quantidade de plantas daninhas juntamente com o mapa, indicam os locais em que se tem maior risco de espalhamento das infestações das plantas daninhas de folha larga já existentes na área. Observa-se que em locais onde não havia plantas invasoras, mas que ocorria infestação nos vizinhos mais próximos, apresentaram alta probabilidade de ocorrência de plantas daninhas devido a influência dos pontos vizinhos na predição dos pontos não amostrados. Na prática, a superfície de probabilidades apresenta uma função de caracterização dos locais com maior risco de severidade de infestação. Com a identificação dos talhões com maiores riscos de estarem infestados, o produtor poderia definir a sequência de pulverização de acordo com os talhões que possuem maiores problemas. Por exemplo, no nosso estudo os talhões centrais apresentam maior probabilidade de ocorrência de plantas daninhas de folha larga, classificando-os como locais prioritários para o manejo.

Apesar de termos obtido bons valores das métricas de avaliação das predições com uso de IVs gerados a partir de imagens PlanetScope (com 3m de resolução espacial) e de variáveis do terreno como predictoras, devido ao nível de detalhamento que é possível obter com a imagem de satélite, a obtenção de pixels puros de plantas daninhas é prejudicada. Isso requer testes do uso dessa metodologia em outra área ou ano agrícola, outra densidade amostral, cultura, ou mesmo com imagens de maior resolução, como as que podem ser obtidas por câmeras embarcadas em aeronave remotamente pilotada (RPA). Além disso, avaliando uma área agrícola por 10 anos, foi observado que a abundância das espécies de plantas daninhas variou entre os anos de estudo, mas os padrões espaciais permaneceram estáveis para observações (PÄTZOLD et al., 2020). Tal estabilidade indica que as variáveis que influenciam a presença dessas plantas podem ser utilizadas para futuras coletas de amostras direcionadas. Logo, a metodologia de classificação de presença-ausência de plantas daninhas de folha larga em pastagem, aplicada neste estudo, pode ser utilizada para o direcionamento de amostragens a partir de covariáveis de sensoriamento remoto e do terreno. Na prática, diminuindo a necessidade de coleta de um grande número de amostras e viabilizando a construção de mapas confiáveis para a prescrição de herbicidas.

Ademais, em um estudo futuro buscaremos validar e melhorar o modelo, e ainda definir covariáveis mais importantes de serem utilizadas e qual o nível de acerto é possível ser obtido em função do tipo de cultura e plantas daninhas presentes na área. Nesse sentido, buscaremos gerar mapas confiáveis para o tratamento localizado de plantas daninhas de folha larga em pastagem. O controle de plantas daninhas por meio da pulverização localizada se caracteriza como uma forma de uso racional de herbicidas, o que pode gerar benefícios ambientais e diminuir custos. O manejo de plantas daninhas em locais específicos se baseia no fato de que tais plantas ocorrem de forma agregada em manchas (MARTÍN et al., 2015). Assim, considerando a seletividade de alguns ingredientes ativos às espécies ou grupo de espécies, como gramíneas (folha estreita) *versus* plantas daninhas de folhas largas por exemplo, é possível ajustar os tratamentos com herbicidas para cada ponto do campo (GUTJAHR et al., 2012).

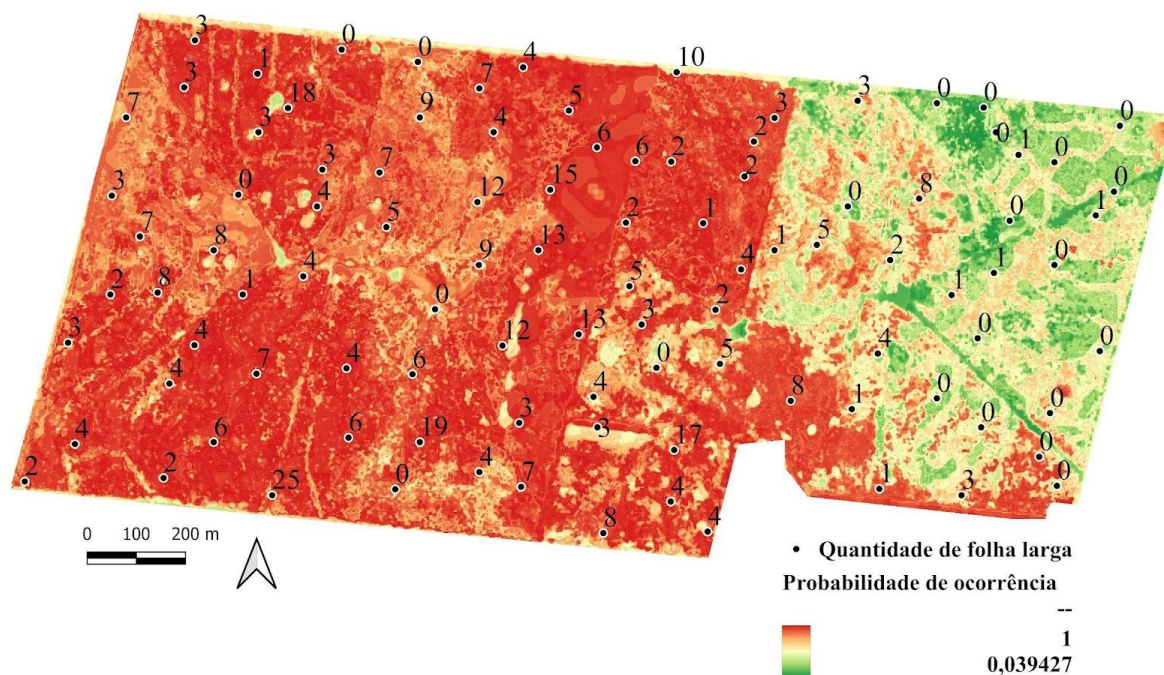


FIGURA 2. Mapa de probabilidade de ocorrência de plantas daninhas de folha larga em pastagem na área de estudo. **Probability map of occurrence of broad-leaved weeds in pasture in the study area.**

**CONCLUSÃO:** Os resultados obtidos neste estudo indicam que a utilização de índices de vegetação e dados do terreno como variáveis preditoras, em modelo de aprendizado de máquina, tem potencial para identificar a presença de plantas daninhas de folha larga em área de pastagem. Estudos adicionais são necessários em outras áreas e com a utilização de sensores que obtenham pixels puros, para que o método seja empregado com maior confiabilidade.

#### AGRADECIMENTOS:

Os autores agradecem aos responsáveis pela fazenda Campina por permitirem a obtenção de dados na área e pelo apoio; à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), processos nº 2017/50205-9 e 2020/02223-0; à Dr<sup>a</sup>. Juliana Campana Pereira e aos colegas do GITAP pelas contribuições e auxílio nas coletas de dados de campo.

#### REFERÊNCIAS

ALMEIDA JÚNIOR, J. J. et al. Plantas Tóxicas De Importância Pecuária Na Região De Perolândia – Go. **Brazilian Journals of Development**, v. 7, n. 7, p. 74029–74045, 2021.

BISCHL B, LANG M, KOTTHOFF L, SCHIFFNER J, RICHTER J, STUDERUS E, CASALICCHIO G, JONES Z. “mlr: Machine Learning in R.” *Journal of Machine Learning Research*, 17(170), 1-5, 2016. <URL: <https://jmlr.org/papers/v17/15-066.html>>

CHIBA, M. K.; FILHO, O. G.; VIEIRA, S. R. Variabilidade espacial e temporal de plantas daninhas em latossolo vermelho argiloso sob semeadura direta. **Acta Scientiarum - Agronomy**, v. 32, n. 4, p. 735–742, 2010.

- FORMAGGIO, A. R.; SANCHES, I. D. **Sensoriamento Remoto em Agricultura**. São Paulo: Oficina de textos, 2017.
- GITELSON, A. A. et al. Remote estimation of leaf area index and green leaf biomass in maize canopies. **Geophysical Research Letters**, v. 30, n. 5, p. 4–7, 2003.
- GITELSON, A. A. et al. Remote estimation of canopy chlorophyll content in crops. **Geophysical Research Letters**, v. 32, n. 8, p. 1–4, 2005.
- 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.
- GUTJAHR, C.; SÖKEFELD, M.; GERHARDS, R. Evaluation of two patch spraying systems in winter wheat and maize. **Weed Research**, v. 52, n. 6, p. 510–519, 2012.
- HENGL, T. et al. Random Forest as a generic framework for predictive modeling of spatial and spatio-temporal variables. n. May, 2018.
- HUETE, A. et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment - Elsevier**, p. 195–213, 2002.
- HUETE, A. R. A soil-Adjusted Vegetation (SAVI). **Remote Sensing of Environment**, p. 295–309, 1988.
- ISH, P. et al. Senna Occidentalis Poisoning: An Uncommon Cause of Liver Failure. **ACG Case Reports Journal**, v. 6, n. 4, p. e00035, 2019.
- JIANG, Z. et al. Remote Sensing of Environment Development of a two-band enhanced vegetation index without a blue band. v. 112, p. 3833–3845, 2008.
- JORDAN, C. F. DERIVATION OF LEAF-AREA INDEX FROM QUALITY OF LIGHT ON THE FOREST FLOOR. **Ecological Society of America**, p. 663–666, 1969.
- KAUFMAN, Y.; TANRE., D. Atmospherically resistant vegetation index. **IEEE Transactions on Geoscience and Remote Sensing**, v. 30, n. 2, p. 260–271, 1992.
- LAMB, D. W.; BROWN, R. B. Remote-sensing and mapping of weeds in crops. **Journal of Agricultural and Engineering Research**, v. 78, n. 2, p. 117–125, 2001.
- LÓPEZ-GRANADOS, F. Weed detection for site-specific weed management: Mapping and real-time approaches. **Weed Research**, v. 51, n. 1, p. 1–11, 2010.
- MARIANO, D. Métricas de avaliação em machine learning: acurácia, sensibilidade, precisão, especificidade e F-score. **BIOINFO - Revista Brasileira de Bioinformática e Biologia Computacional**, n. July, 2021.
- MARTÍN, C. S. et al. Spatial Distribution Patterns of Weed Communities in Corn Fields of Central Spain. **Weed Science**, v. 63, n. 4, p. 936–945, 2015.
- METCALFE, H. et al. Modelling the effect of spatially variable soil properties on the distribution of weeds. **Ecological Modelling**, v. 396, n. November 2018, p. 1–11, 2019.
- MOLIN, J. P.; AMARAL, L. R.; COLAÇO, A. F. **Agricultura de Precisão**. 1. ed. São Paulo: Oficina de textos, 2015.
- MURPHY, P. N. C.; OGILVIE, J.; ARP, P. Topographic modelling of soil moisture conditions: A comparison and verification of two models. **European Journal of Soil Science**, v. 60, n. 1, p. 94–109, 2009.
- NORDMEYER, H. Patchy weed distribution and site-specific weed control in winter cereals. **Precision Agriculture**, v. 7, n. 3, p. 219–231, 2006.

- PÄTZOLD, S. et al. Linking weed patterns with soil properties: a long-term case study. **Precision Agriculture**, v. 21, n. 3, p. 569–588, 2020.
- PETEINATOS, G. G. et al. Potential use of ground-based sensor technologies for weed detection. **Pest Management Science**, v. 70, n. 2, p. 190–199, 2014.
- RAMOS, M. B. et al. The role of edaphic factors on plant species richness and diversity along altitudinal gradients in the Brazilian semi-arid region. **Journal of Tropical Ecology**, v. 36, n. 5, p. 199–212, 2020.
- RATH, A. P. et al. Lantana camara, An Alien Weed for Livestock: A Review. **Annals of Plant Sciences**, v. 5, n. 12, p. 1472, 2016.
- REW, L. J.; COUSENS, R. D. Spatial distribution of weeds in arable crops: Are current sampling and analytical methods appropriate? **Weed Research**, v. 41, n. 1, p. 1–18, 2001.
- ROUSE, J. W. et al. MONITORING VEGETATION SYSTEMS IN THE GREAT PLAINS WITH ERTS. In: **Remote sensing Center**. [s.l.: s.n.]p. 309–317.
- SANTOS, A. C. dos; SALCEDO, I. H.; CANDEIAS, A. L. B. Relação entre o relevo e as classes texturais do solo na Microbacia Hidrográfica de Vaca brava, PB. **Revista Brasileira de Cartografia**, v. 54, 2002.
- SCCON GEOSPATIAL. **Nova geração das imagens PlanetScope**. Disponível em: <<https://www.planet.com/products/planet-imagery/>>. Acesso em: 6 ago. 2021.
- SOUZA, M. F. de et al. Spectral differentiation of sugarcane from weeds. **Biosystems Engineering**, v. 190, p. 41–46, 2020.
- THORP, K. R.; TIAN, L. F. A Review on Remote Sensing of Weeds in Agriculture. p. 477–508, 2004.
- TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127–150, 1979.

# SISTEMA PARA O MONITORAMENTO DA FERRUGEM ASIÁTICA DA SOJA A PARTIR DE COLETORES DE ESPOROS E MAPAS DE FAVORABILIDADE AMBIENTAL

Ivan Carlos Maldaner<sup>1</sup>; Luciano Pes<sup>2</sup>; Luiz Felipe Silveira Pavão<sup>4</sup>; Veronica Fuzer Guarienti<sup>4</sup>; Rafaela da Silva Rodrigues<sup>3</sup>

<sup>1</sup>Eng. Agrônomo, Professor - Colégio Politécnico, UFSM, Santa Maria - RS. ivan.maldaner@ufsm.br / (55) 9 9694-3096; <sup>2</sup>Eng. Agrônomo, Professor - Colégio Politécnico, UFSM, Santa Maria - RS; <sup>3</sup>Curso Técnico em Agropecuária, Graduando - Colégio Politécnico, UFSM, Santa Maria - RS; <sup>4</sup>Curso de Agronomia, Graduando - Centro de Ciências Rurais, UFSM, Santa Maria - RS

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** O presente trabalho busca avaliar o uso de coletores de esporos de *Phakopsora pachyrhizi* e o monitoramento da favorabilidade ambiental como formas de prever o momento do aparecimento dos primeiros sinais de ferrugem asiática em uma lavoura de soja localizada no município de Santa Maria – RS na safra 2021/22. Para tanto, foi utilizado um coletor de esporos desenvolvido pela empresa Smart Consultoria Agronômica e Serviços agrícolas Ltda (Smart Agri) e mapas de favorabilidade ambiental para a ocorrência da ferrugem asiática da soja com base nas condições meteorológicas. Também foi realizada a coleta semanal de 8 folíolos de soja a partir do subperíodo reprodutivo de desenvolvimento da cultura visando monitorar a severidade da ferrugem asiática. Os primeiros esporos de *Phakopsora pachyrhizi* foram identificados no dia 07 de fevereiro de 2022, em número de 2, enquanto que o ambiente apresentou alta favorabilidade para a ocorrência da doença a partir de 07 de março de 2022 e os primeiros sinais da doença na lavoura foram identificados em 14 de março de 2022. O monitoramento da presença de esporos de *Phakopsora pachyrhizi* e o acompanhamento de mapas de favorabilidade ambiental são ferramentas que auxiliam na tomada de decisão para o manejo da ferrugem asiática na cultura da soja.

**PALAVRAS-CHAVE:** *Phakopsora pachyrhizi*; Tomada de decisão; Aplicação precisa

## SYSTEM OF MONITORING ASIAN SOYBEAN RUST INOCULUM FROM SPORE COLLECTORS AND ENVIRONMENTAL FAVORABILITY MAPS

**ABSTRACT:** The present work seeks to evaluate the use of *Phakopsora pachyrhizi* spore collectors and the monitoring of environmental favorability as ways to predict the moment of appearance of the first signs of Asian rust in a soybean crop located in the municipality of Santa Maria - RS in the 2021/22 harvest. For this purpose, we used a spore collector developed by the company Smart Consultoria Agroômica e Serviços Agricultura Ltda (Smart Agri) and environmental favorability maps for the occurrence of Asian soybean rust based on meteorological conditions. A weekly collection of 8 soybean leaflets was also carried out from the reproductive sub-period of crop development in order to monitor the severity of Asian rust. The first spores of *Phakopsora pachyrhizi* were identified on February 7, 2022, numbering 2, while the environment was highly favorable for the occurrence of the disease from March 7, 2022 and the first signs of the disease were identified in March 14, 2022. Monitoring the presence of *Phakopsora pachyrhizi* spores and monitoring environmental favorability maps are tools that assist in decision-making for the management of asian rust in soybeans.

**KEYWORDS:** *Phakopsora pachyrhizi*; Decision making; Precise application

**INTRODUÇÃO:** A soja [*Glycine max* (L.) Merr] é a principal cultura de grãos presente no Brasil, apresentando área cultivada de 40,8 milhões de hectares e expectativa de rendimento de 122,4 milhões de toneladas na safra 2021/22 (CONAB, 2022). Durante o seu ciclo de desenvolvimento, a cultura pode ser afetada por uma série de doenças, dentre as quais destaca-se a ferrugem asiática da soja, cujo agente causal é o fungo *Phakopsora pachyrhizi* e apresenta potencial de reduzir a produtividade da soja em até 80 % no Brasil (CRUZ et al., 2012). Os sintomas da doença manifestam-se na parte abaxial das folhas e ocorrem inicialmente no terço inferior das plantas, na forma de pequenas pontuações denominadas urédias (GODOY et al., 2020).

As urédias são as estruturas reprodutivas do fungo, que ao se romperem liberam os uredosporos, responsáveis pela propagação da doença através do vento. Ao longo do tempo, as folhas que foram infectadas pelo fungo adquirem coloração amarelada, secam e caem, ocasionando a desfolha precoce da cultura, a qual é o principal dano ocasionado pela ferrugem asiática (GODOY et al., 2016). Em geral, para ocorrer o processo de infecção da doença é necessário haver a disponibilidade de água na superfície da folha, com no mínimo seis horas de molhamento e temperaturas entre 15 e 28 °C (GODOY et al., 2020). Tendo em vista a relevância da ferrugem asiática para a cultura da soja, torna-se indispensável que, além de cumprir as principais práticas de manejo para evitar ou amenizar a doença, também sejam incorporadas medidas de monitoramento da favorabilidade ambiental para a presença de esporos, da real presença de esporos e da presença de sinais da doença na área, completando assim o triângulo da doença. Nesse sentido, este trabalho tem como objetivo avaliar o uso de coletores de esporos de *Phakopsora pachyrhizi* e o monitoramento da favorabilidade ambiental como formas de prever o momento do aparecimento dos primeiros sinais de ferrugem asiática em uma lavoura de soja localizada no município de Santa Maria – RS na safra 2021/22.

**MATERIAIS E MÉTODOS:** A pesquisa foi realizada na Área Nova do Colégio Politécnico da Universidade Federal de Santa Maria, no município de Santa Maria, região da Depressão Central do Rio grande do Sul (latitude de 29°43' Sul, longitude de 53°44' Oeste e altitude média de 100 m), na safra 2021/22. O clima da região é o cfa, segundo a classificação de Köppen (KÖPPEN, 1948). A soja, cultivar BMX Valente, foi semeada em 11 de novembro de 2021 em uma área total de 4 hectares, e o coletor de esporos da empresa Smart Agri foi instalado no dia 01 de dezembro de 2021, posicionado a cerca de 450 m da lavoura de soja avaliada. O coletor de esporos é um equipamento constituído por um poste de metal, um painel solar, um porta-lâminas e uma estrutura para abrigar o porta-lâminas. Com esse conjunto de estruturas, o equipamento é capaz de succionar e fazer com que o ar passe por sua parte interna, a qual possui a presença de uma lâmina com fita adesiva de dupla face capaz de captar todas as partículas presentes no ar, inclusive os uredosporos de *Phakopsora pachyrhizi*. A partir do momento da instalação do coletor de esporos, semanalmente as lâminas foram trocadas por novas e aquelas com a presença de partículas de diferentes naturezas foram levadas ao laboratório para análise em microscopia e monitoramento da presença ou ausência de esporos de *Phakopsora pachyrhizi*. Além das coletas e análises dos coletores de esporos, a partir do dia 28 de janeiro de 2022, quando a cultura estava iniciando o seu subperíodo reprodutivo, passou-se a coletar 8 folíolos do terço médio das plantas semanalmente. Tais coletas foram efetuadas em uma região da lavoura que abrange 1 ha e que não recebeu nenhuma aplicação de fungicidas, visando facilitar a entrada imediata do patógeno na área assim que houvesse condições ambientais favoráveis. Os folíolos coletados foram acondicionados em sacos plásticos, levados até o laboratório e analisados com o uso de uma lupa, visando assim identificar criteriosamente a presença ou não das primeiras urédias no tecido foliar das plantas. A partir da visualização dos primeiros sinais da doença, passou-se a realizar a tabulação da severidade da doença em cada folíolo com base na escala diagramática desenvolvida por Godoy et al. (2006). Os mapas de favorabilidade ambiental para a ocorrência da ferrugem asiática da soja no RS foram criados com base nos dados de temperatura, umidade relativa do ar e precipitação, os quais são inseridos em equações de favorabilidade validadas e calculados diariamente. Os resultados são apresentados através de classes variando de muito baixa a muito alta favorabilidade ambiental para a ocorrência da doença nas diferentes regiões do estado.

**RESULTADOS E DISCUSSÃO:** O primeiro esporo de ferrugem asiática foi detectado somente no dia 07 de fevereiro de 2022, cerca de 69 dias após a instalação do coletor de esporos, enquanto que a primeira manifestação da doença na área ocorreu em 14 de março de 2022, 35 dias após a identificação do primeiro esporo. Na Figura 1 é apresentada a variação da severidade do fungo *Phakopsora pachyrhizi* através dos dados obtidos a partir das análises de folíolos e leitura das lâminas do coletor de esporos. Em geral, foi possível observar que a partir da identificação do primeiro esporo, ocorreram variações semanais no número de esporos encontrado, mas houve a sua presença em todas as análises realizadas até o início de abril, período em que a soja já estava no final do seu ciclo. Nota-se, no entanto, uma distinção temporal entre a captura do primeiro esporo e o início da manifestação dos primeiros sinais/sintomas da doença na lavoura, o que pode ser explicado pela atuação de fatores como a quantidade e viabilidade do inóculo inicial, as condições meteorológicas

durante o período de avaliação, o período de implantação das culturas, entre outros (OLIVEIRA et. al., 2020).

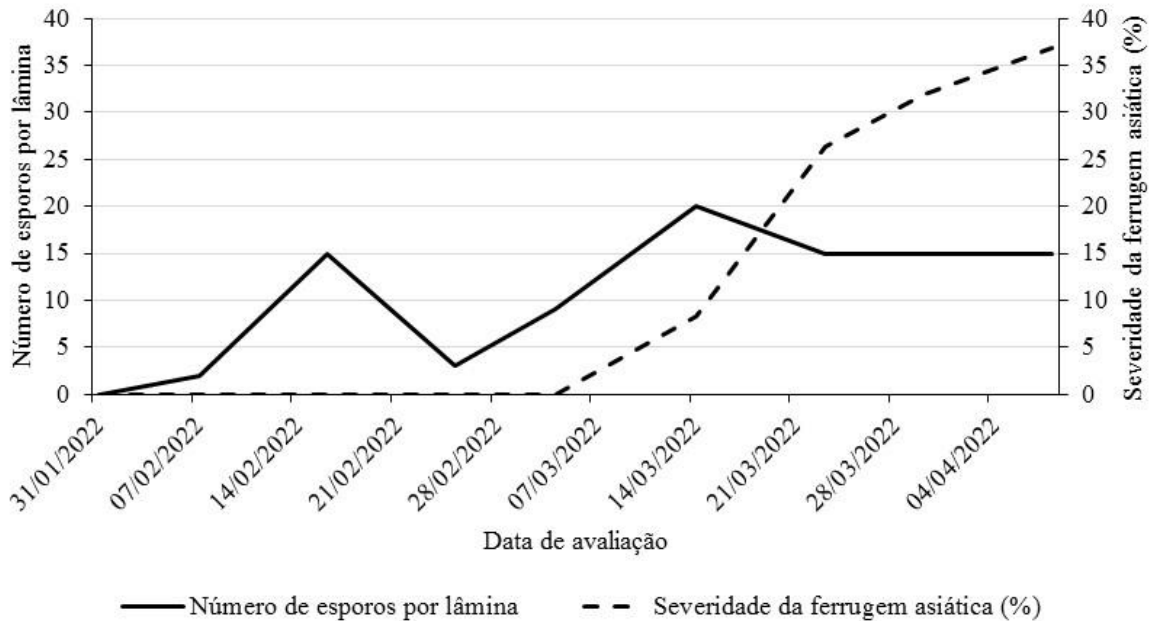


FIGURA 1. Variação semanal do número de esporos de *Phakopsora pachyrhizi* a partir da sua primeira identificação e severidade média da ferrugem asiática da soja em 8 folíolos de soja. Fonte: Pavão, 2022. **Weekly variation of *Phakopsora pachyrhizi* spore number from its first identification and mean severity of Asian soybean rust on 8 soybean leaflets. Source: Pavão, 2022.**

A favorabilidade ambiental para o surgimento e estabelecimento da ferrugem asiática da soja foi baixa na grande maioria das regiões do RS em função dos pequenos volumes de chuva. Conforme é mostrado na Figura 2, a condição ambiental para a ocorrência da doença esteve favorável em um pequeno período entre final de janeiro e início de fevereiro em algumas regiões do estado. A partir da metade da primeira quinzena de fevereiro a condição esteve desfavorável para a ocorrência da doença em todas as regiões, fenômeno que se explica especialmente pela escassez de chuvas no estado nas referidas datas. A partir do início de março, no entanto, as chuvas voltaram, fato que permitiu a presença de uma condição ambiental favorável para a instalação da ferrugem asiática na maioria das regiões, incluindo a Depressão Central.

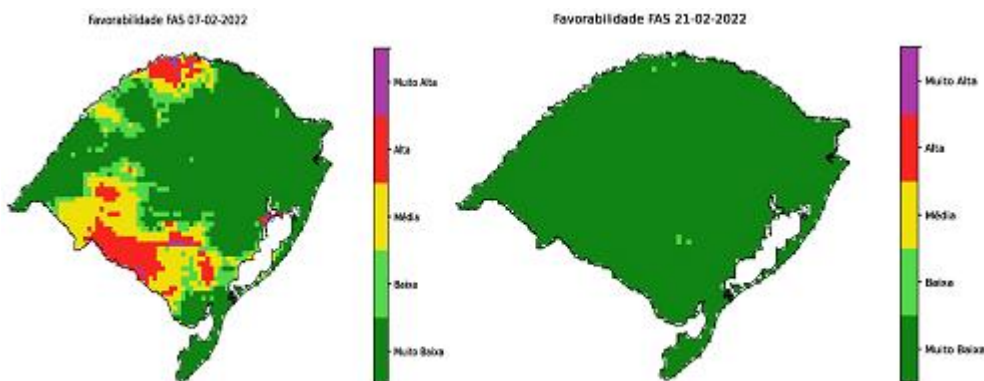
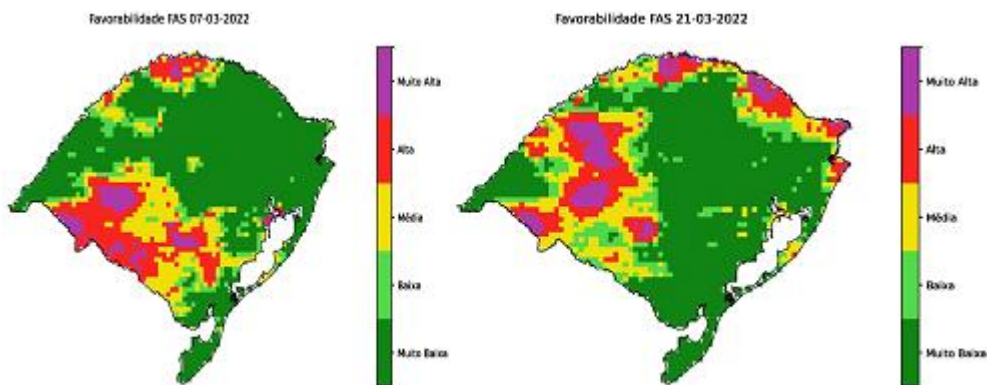


FIGURA 2. Mapas de favorabilidade ambiental para a ocorrência de ferrugem asiática da soja em diferentes datas de avaliação no mês de fevereiro de 2022. Fonte: Smart Agri, 2022. **Environmental favorability maps for the occurrence of Asian soybean rust at different assessment dates in February 2022. Source: Smart Agri, 2022.**

FIGURA 3. Mapas de favorabilidade ambiental para a ocorrência de ferrugem asiática da soja em diferentes datas de avaliação no mês de março de 2022. Fonte: Smart Agri, 2022. **Environmental favorability maps for the occurrence of Asian soybean rust on different assessment dates in March 2022. Source: Smart Agri, 2022.**





De maneira geral, os primeiros esporos encontrados antes do aparecimento dos sinais iniciais da ferrugem asiática na lavoura coincidiram com um período de ambiente favorável para a ocorrência da doença em algumas regiões do estado, muito embora essa quantidade de esporos e condição ambiental não tenham sido suficientes para o aparecimento dos primeiros sinais de ferrugem asiática no campo. Com o decréscimo da favorabilidade ambiental ocorrido a partir da metade da primeira quinzena de fevereiro, foi visível também um decréscimo na quantidade de esporos capturados e a área de lavoura permaneceu sem o estabelecimento da ferrugem asiática. A partir do início de março, visualizou-se a crescente favorabilidade ambiental para a ocorrência da doença, acompanhada do aumento no número de esporos capturados e do início do aparecimento dos primeiros sinais da doença nos folíolos da soja. Sistemas de monitoramento com coletores de esporos, como mapas de favorabilidade ambiental e avaliação da presença de sintomas de ferrugem asiática da soja são uma estratégia que permite prever o momento em que a lavoura de soja estará mais suscetível a apresentar os primeiros sinais da ferrugem asiática da soja. Na prática, tal estratégia torna-se importante para que se consiga realizar as aplicações de fungicidas na soja de maneira mais assertiva, deixando de lado o antigo modelo de aplicações calendarizadas. Com essa estratégia é possível reduzir o número de aplicações de fungicida ou, caso não se tenha esporos e favorabilidade ambiental para o desenvolvimento da ferrugem asiática da soja, realizar aplicações de fungicida com menor custo focando no complexo de doenças que ocorrem na cultura da soja.

**CONCLUSÃO:** Verifica-se a partir deste trabalho que sistemas de monitoramento da ferrugem asiática da soja através do coletor de esporos de *Phakopsora pachyrhizi* aliado ao acompanhamento de mapas de favorabilidade ambiental e a avaliação da presença dos sintomas de doença nos folíolos de soja fecham o triângulo da doença e são importantes ferramentas para a tomada de decisão no manejo com sustentabilidade da ferrugem asiática na cultura da soja, reduzindo o número de aplicações de fungicida e, diminuindo o custo de produção para o produtor rural.

#### AGRADECIMENTOS:

Agradecimento especial à **Smart Consultoria Agrônômica e Serviços Agrícolas Ltda.** pela geração dos mapas de favorabilidade ambiental e disponibilização do coletor de esporos para a coleta dos dados.

#### REFERÊNCIAS

CONAB - COMPANHIA NACIONAL DE ABASTECIMENTO . **Acompanhamento da Safra Brasileira de Grãos**, Brasília, DF, v. 9, safra 2021/22, n. 7, sétimo levantamento, abril 2022. Disponível em: <<https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos>>. Acesso em: 25 abr. 2022.

CRUZ, T. V. et al. Perdas causadas pela ferrugem-asiática em cultivares de soja semeadas em diferentes épocas, no Oeste da Bahia. **Tropical Planta Pathology**, vol. 37, p. 255-265, jul-ago, 2012. Disponível em: <<https://www.scielo.br/j/tpp/a/s9Mhy5wXRcXBbc4TQLsc8Zg/?lang=pt#>>. Acesso em: 24 abr. 2022.

GODOY, C.V. et al. Diagrammatic scale for assessment of soybean rust severity. **Fitopatologia Brasileira**, vol 31, p. 63-68, jan-fev, 2006. Disponível em:  
<<https://www.scielo.br/j/fb/a/7zsWfRPH6xXNGHjsS4ZSNwN/abstract/?lang=en>>. Acesso em: 24 dez. 2021.

GODOY, C. V. et al. Doenças da soja. In: AMORIM, L. et al. (Ed.). **Manual de fitopatologia: doenças das plantas cultivadas**. 5. ed. Ouro Fino: Agronômica Ceres, 2016, v.2. p. 657-675.

GODOY, C. V. et al. **Ferrugem-asiática da soja**: bases para o manejo da doença e estratégias antirresistência. Embrapa Soja: Londrina, PR, 2020, 40p. Disponível em:  
<<https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1122923/1/DOC-428.pdf>>. Acesso em: 24 abr. 2022.

KÖEPPEN, W. **Climatologia**: Con un estudio de los climas de la tierra. Fondo de Cultura Economica, México, 1948.

OLIVEIRA, G. M et al. Coletor de esporos: descrição, uso e resultados no manejo da ferrugem-asiática da soja. **Circular Técnica**, Londrina: Embrapa Soja, n. 167, 2020. 18 p.

## **interação entre a infestação DE PHOMA E indicadores de solo e planta EM LAVOURA DE CAFÉ NO PLANALTO DE VITÓRIA DA CONQUISTA-BA**

**Derlei Dias Melo<sup>1</sup>; Odair Lacerda Lemos<sup>5</sup>; Ingrid Thalia Prado de Castro<sup>3</sup>; Leandro Dias da Silva<sup>4</sup>; Juliana Santos Abrantes Silva<sup>2</sup>**

<sup>1</sup>Estudante de Engenharia Agrônômica , Graduando - Laboratório de Geotecnologias Aplicadas, UESB, Vitória da Conquista-BA. derleim8@gmail.com / (77) 9 8827-2462; <sup>2</sup>Estudante de Engenharia Florestal , Graduando - Laboratório de Geotecnologias Aplicadas, UESB, Vitória da Conquista-BA; <sup>3</sup>Engenheira Agrônoma , Doutoranda - Laboratório de Geotecnologias Aplicadas, UESB, Vitória da Conquista-BA; <sup>4</sup>Engenheiro Florestal, Graduado - Laboratório de Geotecnologias Aplicadas, UESB, Vitória da Conquista-BA; <sup>5</sup>DSc. Engenheiro Agrônomo , Professor - Laboratório de Geotecnologias Aplicadas, UESB, Vitória da Conquista-BA

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** O cultivo do café é de suma importância para a região do planalto da conquista no estado da Bahia, pois este apresenta indicação geográfica propicia a cultura do café arábica, o qual representa o *commodity* agrícola de maior potencial produtivo da região. Alguns fatores limitam e até reduzem a produtividade do cafeeiro, entre estes a Mancha de Phoma e a compactação do solo. Diante disso foi avaliado a interação entre infestação de Phoma e indicadores de solo e planta, em uma lavoura de Café na região do Planalto de Vitória da Conquista. A maior parte do solo apresentou resistência a penetração (RP) acima 2,47 MPa, enquanto o indicado para a cultura é abaixo de 2,00 Mpa. Houve uma baixa correlação entre RP com a infestação Mancha de Phoma, e baixa a média correlação negativa entre mancha de Phoma e teores de clorofila.

**PALAVRAS-CHAVE:** Resistencia a penetração; Mapas de infestação ; Distribuição espacial

### **INTERACTION BETWEEN PHOMA INFESTATION AND SOIL AND PLANT INDICATORS IN COFFEE CROPS IN THE PLATEAU OF VITÓRIA DA CONQUISTA-BA**

**ABSTRACT:** The cultivation of coffee is of paramount importance for the region of the plateau of conquest in the state of Bahia, as this has a geographical indication favors the cultivation of arabica coffee, which represents the agricultural *commodity* with the greatest productive potential in the region. Some factors limit and even reduce coffee productivity, including Phoma stain and soil compaction. Therefore, the resistance to soil penetration (RP), the Phoma stain infestation and the chlorophyll indices of the coffee plants were evaluated, elaborating maps of distribution and correlation between the variables. Most of the soil showed penetration resistance (RP) above 2.47 MPa, while the recommended for the crop is below 2.00 MPa. There was a low correlation between RP and Phoma spot infestation, and low to medium correlation between Phoma spot and chlorophyll levels.

**KEYWORDS:** Resistance to penetration; Infestation maps; Spatial distribution

**INTRODUÇÃO:** O cultivo do café é de suma importância para a economia Brasileira, fato evidenciado por seu volume de produção, tendo em vista que na safra de 2022 é esperada uma produtividade média de 30,6 sacas por ha, apresentando uma expectativa de 55.743,1 mil sacas de café beneficiado. (CONAB, 2022)

Segundo Dutra Neto e da Silva (2018), o Planalto de Vitória da Conquista é conhecida no mercado de café Nacional e Internacional como uma área de produção de café despulpado de alta qualidade, detentora de prêmios em concursos de cafés em nível Nacional e Estadual.

Fatores como presença de pragas, doenças, condições climáticas e de solo limitam a produção. Uma das doenças que afeta o cafeeiro é a Mancha de Phoma (*Phoma tarda*) essa tem sido problemática em áreas cafeeiras com altitudes superiores a 900m sujeitas a ventos frios, principalmente, nos anos com excesso de chuvas de inverno e temperatura entre 19 a 20° C. (JUNIOR et al. 2018).

Desequilíbrios nutricionais podem predispor as plantas ao ataque do patógeno devido ao esgotamento dos ramos produtivos (JUNIOR et al. 2018). Uma das formas de avaliar o teor nutricional de plantas é através de leituras de clorofila, já que os teores de nitrogênio apresentam correlação positiva com as leituras realizadas em folhas de diversas espécies cultivadas. (KURTZ et al. 2022)

Segundo Da Silva (2021) A compactação do solo pode afetar de forma negativa o arranjo estrutural do solo acarretando um menor crescimento das raízes comprometendo o desenvolvimento das culturas em função da baixa absorção de água e nutrientes pelas plantas. Com a melhoria das condições do ambiente de desenvolvimento radicular, há maior desenvolvimento do aparato fotossintético da planta .

As ferramentas de agricultura de precisão estão bastante difundidas nas principais espécies cultivadas em diferentes sistemas de produção agrícola do país. A agricultura de precisão é uma técnica de manejo que considera a variabilidade espacial e permite a aplicação sítio-específica de insumos, como fertilizantes, corretivos, pesticidas, e mapas de predição de pragas. (BASSOI et al. 2019).

A geoestatística é uma ferramenta importante para análise de dados, no âmbito da agricultura de precisão. Segundo Ferraz et al. (2011), o objetivo da geoestatística aplicada à agricultura de precisão é caracterizar a variabilidade espacial dos atributos do solo e das plantas e fazer estimativa, utilizando o princípio da variabilidade espacial a fim de se identificar inter-relações desses atributos no espaço e no tempo, além de permitir estudar padrões de amostragem adequada.

Diante disso, o objetivo deste trabalho foi utilizar técnicas de agricultura de precisão, aliada as ferramentas da geoestatística para avaliar a interação entre infestação de Phoma e indicadores de solo e planta, em uma lavoura de Café na região do Planalto de Vitória da Conquista.

**MATERIAIS E MÉTODOS:** O trabalho foi desenvolvido na Fazenda Pau Brasil, em uma área produtora de café no município de Barra do Choça BA, o qual compõem a região produtora do Planalto da Conquista, em um talhão de cerca de 5 hectares, com plantio de café arábica, cultivar Catuaí, com espaçamento de 4 metros entre linhas e 1,0 metros entre plantas, em idade produtiva de 20 anos. A região do presente estudo possui clima tropical com estação seca (Classificação climática de Köppen-Geiger: Aw).

Para a coleta de dados a área foi dividida em um grid amostral regular, de 50 pontos com espaçamento entre pontos de 30x30 m, sendo estes georreferenciados em campo por meio do receptor GNSS. Cada ponto amostral correspondeu a seis plantas de café, sendo três em cada lado de linha que há incidência solar ao lado nascente e três ao lado poente;

Com o auxílio de um penetrômetro de impacto de Stolf foi realizado a avaliação de resistência a penetração, nos limites da saia de três plantas de café na linha onde o ponto foi localizado. A resistência foi contabilizada até as profundidades de 0-20 e 20-40 cm.

Para as avaliações do índice de clorofila, foram selecionadas três plantas ao lado nascente do sol, e três plantas ao lado poente do sol nas linhas do ponto, e em cada uma destas foi realizado a leitura no terceiro par de folhas totalmente expandido com o auxílio do medidor de clorofila, o ClorofiLOG Falker CFL1030. A contabilização da incidência da Mancha de Phoma foi realizada através da ausência e presença dos sintomas nas seis plantas de café, que se encontram em torno do ponto, três nas linhas do lado nascente e três na poente do sol; atribuindo valores de 0 para ausência de Phoma e 1 para ocorrência.

Para representação espacial, foi utilizado o software ArcMap, que possui em seu banco de dados as técnicas de interpolação IDW e Krigagem (NUNES et al. 2018) as quais foram aplicadas para confecção dos mapas de atributos avaliados. Os dados obtidos após a interpolação foram submetidos a correlação de Pearson para verificar possíveis correlações.

**RESULTADOS E DISCUSSÃO:** A estatística descritiva para os resultados de resistência a penetração (RP) em lavoura de café (Tabela 1) descreve o comportamento dos dados da área em estudo. Segundo Vargas et al (2013) os valores acima de 2,0 MPa já tornam impeditivos o pleno desenvolvimento radicular da planta, este

valor sendo considerado ponto crítico, é inferior ao menor valor amostrado na área, que foi de 2,47 MPa, encontrados nas profundidades de 0-20 cm. O valor máximo foi 6,47 MPa, também superior aos resultados de Effgen et al (2012) que encontra valores de 5,1 MPa nas camadas de 20-40 cm, ressaltando que tais valores tornam desfavorável o desenvolvimento do sistema radicular, desfavorecendo a planta na absorção de nutriente a água.

A RP nas profundidades de 20-40 Cm foram inferiores a da camada mais superficial, apresentando média de 3,22 MPa, o que é um valor ainda superior ao recomendado, no entanto apresenta valores mínimos abaixo de 2,0 MPa, de forma que não é todo o cafezal que está sobre compactação, e em comparação com os resultados de 0-20 cm, demonstram que os trabalhos de descompactação teriam que ser realizados em área total apenas nas camadas superiores.

Oliveira et al. (2014) relata que diferentes práticas de manejo contribuem para compactação do solo, causando restrição a infiltração de água no perfil do solo. Fernandes et al (2012) em seus trabalhos apresenta ganhos significativo relacionados ao aumento de produtividade após a subsolagem de lavouras cafeeiras em relação a áreas compactadas.

TABELA 1. Estatística descritiva das variáveis estudadas. **Descriptive statistics of the variables analyzed.**

Variáveis	Min	Max	Média	Desvio Padrão
RP 0-20 cm	1,52	4,97	3,22	0,39
RP 20-40 cm	2,47	6,47	4,37	0,64
Clorofila lado Nascente	56,44	77,42	65,52	2,63
Clorofila lado Poente	54,00	76,17	62,39	3,06
Probabilidade Phoma – Nascente	0,00	0,3892	0,11	0,09
Probabilidade Phoma – poente	0,00	1,0	0,40	0,30

Trabalhos utilizando um clorofilômetro para realizar a leitura de clorofila foram realizados por Sousa et al. (2020) com intuito de observar a relação entre clorofila e as faces de exposição solar do cafeeiro, encontrou valores médios de clorofila de 53,57 para a face norte e 64,08 para a face sul. Ladeia et al. (2019) também realizou leituras de clorofila em trabalho feito em lavouras de café no Planalto da Conquista, encontrando valores médios de 41,53 de clorofila para a variedade Catuaí e 42,83 para a variedade Acauã. Ambos inferiores aos encontrados no presente estudo

TABELA 2. Comparação entre médias de teor de clorofila em plantas de café no Planalto da Conquista-BA. **Comparison between averages of chlorophyll content in coffee plants in the Planalto da Conquista-BA**

Variável	Mínimo	Máximo	Média	p-valores
Clor.Linha/Nascente	56,41	77,45	65,42b	<0,0001
Clor.Linha/Poente	54,00	76,20	62,25a	<0,0001

Médias seguidas por mesma letra na coluna não diferem entre si pelo teste T a 5% de probabilidade

Conforme ainda demonstrado na tabela 2, os valores médios de clorofila apresentaram diferença estatística entre si, com maior média para as plantas na linha que recebem incidência do sol nascente. Resultados estes corroboram com Petrim e Almeida (2020) onde seus trabalhos demonstram que a face do cafeeiro exposta ao sol poente apresentaram menores teores de clorofila foliar em relação à face de exposição ao sol nascente. Borghetti (2013) ressalta que o cafeeiro pode apresentar comportamentos distintos conforme a orientação das faces de exposição ao sol. Speranza et al. (2019) também teve resultados significativos sobre a clorofila em relação as faces de exposição do cafeeiro ao sol nos seus trabalhos estudando zonas de manejo.

Quanto aos dados de Mancha de Phoma pode se notar que apresentaram valores baixos, e com baixa taxa de infestação, ressaltando que a época de avaliação foi em meados do outono, período que as temperaturas ainda estão mais elevadas na região. Junior et al. (2019) ressaltou que a umidade relativa alta, bem como as baixas temperaturas favorecem a incidência da doença em seus experimentos.

Quanto aos valores de RP, teores de clorofila e a incidência de Phoma estão apresentados nas figuras 1, 2 e 3.

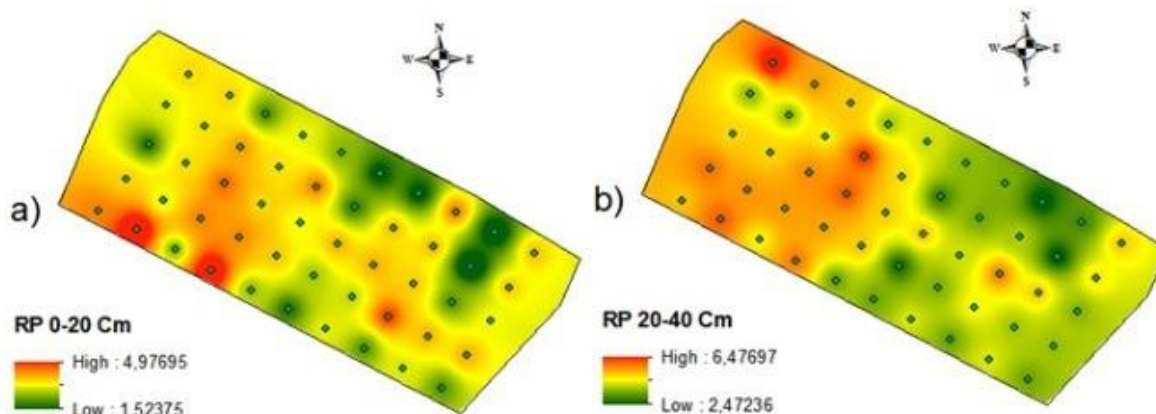


FIGURA 1. Mapas de resistência à penetração do solo em diferentes camadas. Obtidos por IDW. **Maps of resistance to soil penetration in different layers, obtained by IDW**

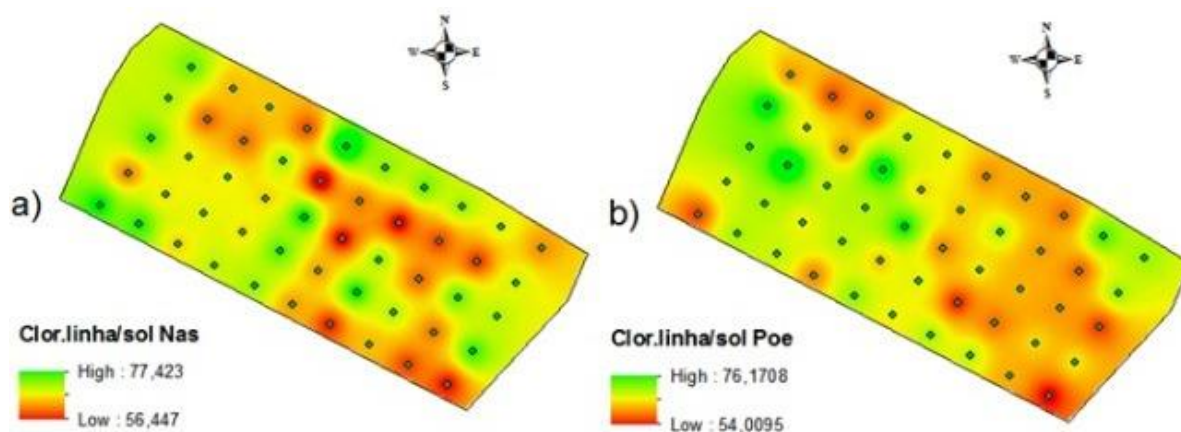


FIGURA 2. Mapas de clorofila em plantas de cafeeiro, que recebem diferentes incidências solares ao longo do dia. Obtidos por IDW. **Chlorophyll maps in coffee plants, which receive different solar incidences throughout the day. Obtained by IDW**

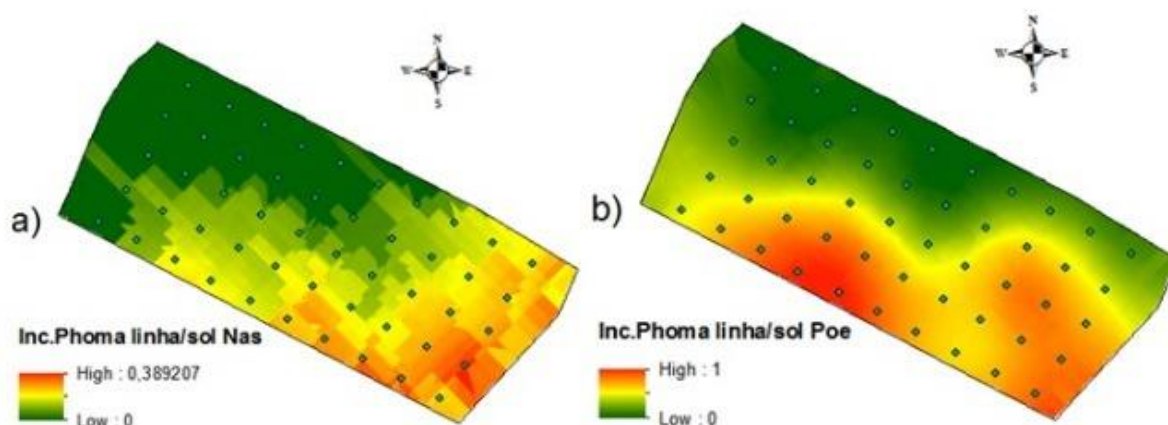
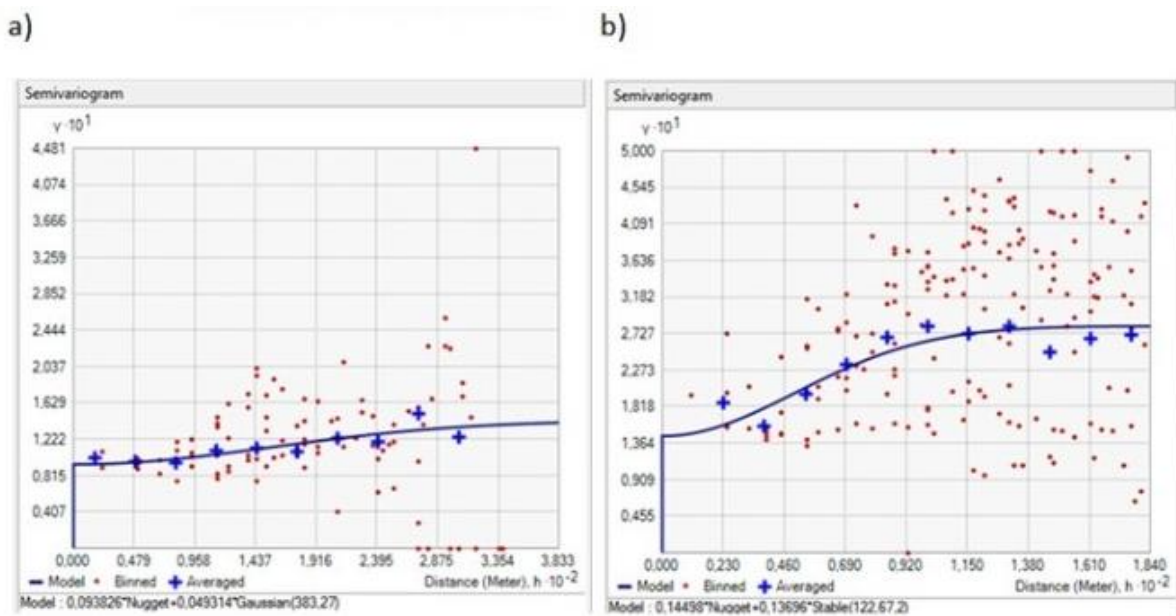


FIGURA 3. Mapas de probabilidade de infestação de Phoma em plantas de cafeeiro, que recebem diferentes incidências solares ao longo do dia. Obtidos por Krigagem Indicadora. **Probability maps of Phoma**



**infestation in coffee plants, which receive different solar incidences throughout the day. Obtained by Indicator Kriging**



**FIGURA 4. Semivariogramas de infestação de Phoma em plantas de cafeeiro, que recebem diferentes incidências solares ao longo do dia. Obtidos por Krigagem Indicadora. Semivariograms of Phoma infestation in coffee plants, which receive different solar incidences throughout the day. Obtained by Indicator Kriging**

Os mapas de distribuição espacial revelam maiores compactações de solo na região noroeste do talhão, tanto para as profundidades de 0-20 cm, quanto para a profundidades de 20-40 cm, com valores acima de 3,5 MPa nas avaliações mais superficiais e valores superiores a 4,5 MPa em maiores profundidades.

Carvalho (2012) Encontrou correlação negativa entre altura de plantas de café e RP do solo, Carvalho et al. (2010) encontraram correlação positiva entre produtividade e altura de plantas de café. Até o momento não houve colheita dos frutos para validar se a compactação no solo cause perda na produtividade da área de estudos.

Quanto aos mapas de clorofila, estes apresentam maiores valores na região central do talhão, com valores superiores a 65 nessas regiões, e menores teores de clorofila nas extremidades, em especial na parte sudeste.

O percentual de probabilidade de infestação de Phoma foi apresentado nas regiões sul e sudeste do talhão, com taxas de 38% de probabilidade para as linhas de café que recebem incidência solar nascente e 100 % de probabilidade para as linhas de café que recebem incidência solar poente.

Após a confecção dos mapas de distribuição espacial das variáveis, foi realizada a correlação de Pearson conforme valores apresentados na tabela 3. Sendo possível observar correlações de -0,9 e -0,44 entre as variáveis RP 0-20cm, RP 20-40cm e manchas de Phoma Nas, respectivamente.

A RP de 0-20 Cm apresentou correlação de 61% com a RP de 20-40 Cm, demonstrando que nas camadas superficiais que apresentam compactação influenciam na compactação das camadas mais inferiores.

**TABELA 3. Correlação de Pearson para as variáveis estudadas em lavoura de Café no Planalto da Conquista-BA. Pearson's correlation for the variables studied in coffee plantations in the Planalto da Conquista-BA.**

	RP 0-20 cm	RP 20-40 cm	CI Nas	CI Poe	Phoma Nas	Phoma Poe
--	------------	-------------	--------	--------	-----------	-----------



RP 0-20 cm	1					
RP 20-40 cm	0,61	1				
Cl Nas	0,11	-0,23	1			
Cl Poe	0,10	0,36	0,14	1		
Phoma Nas	-0,9	-0,44	-0,18	-0,32	1	
Phoma Poe	0,21	-0,12	-0,02	-0,25	0,74	1

\*RP= Resistência a penetração no solo, Cl= Clorofila, Nas= Linha do sol Nascente, Poe= Linha do sol Poente, Phoma= Manchas de Phoma na planta. A 5% de probabilidade.

Oliveira et al. (2022) ao avaliar correlação entre RP e Clorofila em plantas de milho constatou baixa correlação, o que corrobora com o presente estudo, haja vista que a RP tanto nas profundidades de 0-20 cm e 20-40 cm apresentaram baixa correlação positiva com os teores de clorofila

Para as variáveis de teores de clorofila em plantas de café em linhas de diferentes incidências solar e incidência de Phoma houve correlação moderada. A correlação entre a Phoma da linha onde o sol incide no poente e nascente apresentaram percentuais de -0,32 e -0,18 onde esses foram os maiores valores de correlação. Segundo Martiello et al. (2019) a ocorrência de Phoma em área de altitudes mais elevadas favorecem maior incidência do patógeno na face que não recebe a incidência solar pela manhã, já que a mesma vai manter por mais tempo a umidade do orvalho noturno sobre a folhagem. De acordo com Lima et al. (2010) o desequilíbrio do nitrogênio e do potássio faz plantas de café ficarem mais susceptível a infecção de Phoma, mostrando que a nutrição tem influência direta sobre a doença. Martiello et al. (2015) ressalta que doenças como a Phoma é favorecido por condições de excesso de nitrogênio em relação ao potássio, o que é comum nas regiões de altitude elevada, mais frias e nubladas, onde a atividade do nitrato redutase é mais eficiente e o consumo de nitrogênio é menor, e já naturalmente tende a haver excesso do nutriente. Essas características condizem como local de plantio do café estudado, tendo em vista que o Planalto da conquista se caracteriza pelo clima com temperaturas mais amenas e a altitude do cafezal está superior a 900 metros em relação ao nível do mar.

Esses valores por apresentarem moderada correlação negativa demonstram indícios para novas avaliações, em especial nas estações de outono e inverno que são os períodos mais propícios a incidência da doença. Krohling et al. (2015) verificou que o ataque de phoma ocorreu com altos níveis de infecção, pelas condições de temperatura baixa, e, principalmente pela alta umidade observada, por chuvas constantes e UR alta durante cerca de 15 dias em junho que condizem com o final do outono e início do inverno.

**CONCLUSÃO:** As ferramentas de geoestatística possibilitaram a interpretação dos dados da área em estudo, de forma que houve compactação na área implantada com lavoura de café, tanto nas profundidades de 0-20 cm quanto na de 20-40 cm, havendo correlação entre RP em ambas as camadas, demonstrando que onde há compactação de 0-20 cm há 60% de chances de possuir compactação na camada de 20-40 Cm. Houve correlação moderada entre a compactação do solo e os teores de clorofila das plantas de café. A lavoura apresentou altas taxas de infestação de Phoma, e a mesma apresentou moderada correlação negativa com os teores de clorofila das plantas apresentando indícios que baixos teores de clorofila favorecem o surgimento do patógeno. Por ser uma época de menores proporções de ataque de Phoma em plantas de café, ainda cabe estudos sobre sua correlação com os índices de clorofila em diferentes estações do ano nos cafezais do Planalto da Conquista.

## REFERÊNCIAS

BADINELLI, P. G.; JUNIOR, D. F. U.; DE MORAES, F. A. Estratégias de descompactação de solos hidromórficos cultivados com soja. In Congresso Brasileiro de arroz irrigado, pp. 3-10. (2019)

BASSOI, L. H., INAMASU, R. Y., BERNARDI, A. D. C., VAZ, C. M. P., SPERANZA, E. A., & CRUVINEL, P. E. Agricultura de precisão e agricultura digital. **Embrapa Pecuária** Sudeste-Artigo em periódico indexado (*ALICE*), 2019.

BORGHETTI, R. A. Aspectos nutricionais e fisiológicos associados à produção do cafeeiro com alinhamento de plantio norte-sul.40p. **Dissertação (Mestrado em Solos e Nutrição de Plantas)** Universidade Federal de Viçosa, 2013.

CARVALHO, L.C. C. Variabilidade espacial de atributos físicos do solo e características agronômicas da cultura do café. 2012.

Carvalho, A. M. D.; Mendes, A. N. G.; Carvalho, G. R.; Botelho, C. E.; Gonçalves, F. M. A.; Ferreira, A. D. Correlação entre crescimento e produtividade de cultivares de café em diferentes regiões de Minas Gerais, Brasil. *Pesquisa agropecuária brasileira*, 45, 269-275, 2010.

CONAB. COMPANHIA NACIONAL DE ABASTECIMENTO. Acompanhamento de safra brasileiro – Café: primeiro levantamento, janeiro 2022 – safra 2022. : Brasília: **Companhia Nacional de Abastecimento**. 2022. Disponível em: <http://www.conab.gov.br>. Acesso em: 02 mai. 2022.

DA SILVA, P.L. F. Compactação e seus efeitos sobre o funcionamento do solo e a absorção de nutrientes pelas plantas: Uma revisão bibliográfica. **Meio Ambiente (Brasil)**, v. 3, n. 2, 2021.

DUTRA NETO, C., & DA SILVA, G. R. Fatores que comprovam exclusivamente ou essencialmente a qualidade do café despulpado pelo meio geográfico, incluindo os fatores ambientais para indicação geográfica-denominação de origem-do planalto de Vitória da Conquista-Bahia. **CBPC** (2018).

EFFGEN, T. A. M.; PASSOS, R. R.; ANDRADE, F.V.; LIMA, J. S de S.; REIS, E. F. & BORGES, E. N. Propriedades físicas do solo em função de manejos em lavouras de cafeeiro conilon. **Revista Ceres**, 59:414-421, 2012.

FERNANDES, A. L.; SANTINATO, F.; SANTINATO, R. Utilização da subsolagem na redução da compactação do solo para produção de café cultivado no cerrado mineiro. *Enciclopédia Biosfera*, 8(15). 2012

MARTIELLO, J.B.; SANTINATO, R.; ALMEIDA, S.R.; GARCIA, A. W.R.; Vultura do café no Brasil: manual de recomendações: ed. 2015/ 1. ed. – São Paulo : **Futurama Editora**, 2016.

MENEZES-SILVA, P. E.; SANGLARD, L. M.; ÁVILA, R. T.; MORAIS, L. E.; MARTINS, S. C.; NOBRES, P.; DAMATTA, F. M. Photosynthetic and metabolic acclimation to repeated drought events play key roles in drought tolerance in coffee. *Journal of Experimental Botany*, 68(15), 4309-4322. 2017

NUNES, E. H.; MACHADO, T. M.; REYNALDO, É. F.; PEREIRA, C. S. Métodos de interpolações de dados obtidos por sensores de agricultura de precisão, *Nativa*, 6(6), p. 681-688. doi: 10.31413/nativa.v6i6.5428, 2018.

JUNIOR, E. C. C., DE FREITAS, A. S., ALCANTRA, E., REZENDE, R. M., DE LOURDES OLIVEIRA, M., & RIBEIRO, D. F. (2019). Incidência de ferrugem, cercosporiose e mancha de phoma em cafeeiro sob diferentes tipos de poda. *Revista da Universidade Vale do Rio Verde*, 16(3). (2019).

KROHLING, C. A.; MATIELLO, J. B.; ALMEIDA, S. R.; RODRIGUES, V. R.; KROHLING, C. C. K. Avaliação do ataque da mancha de Phoma em variedades de café arábica. **SBIfcafé** (2015)

KURTZ, C.; PAULETTI, V. .; MENEZES JÚNIOR, F. O.G .; MORA, C. Diagnóstico de nitrogênio pelo índice de clorofila e nitrato na seiva para cebola em sistema de semeadura direta. **Revista Thema**, [S. l.], v. 21, n. 1, p. 92–114, 2022. DOI: 10.15536/thema.V21.2022.92-114.2368. Disponível em: <https://periodicos.ifsul.edu.br/index.php/thema/article/view/2368>. Acesso em: 2 maio. 2022.

- LADEIA, C. A.; SANTOS, J. R. E. D.; SOUSA, D. S.; FREIRE, D. S.; CASTRO, I. T. P. D.; FERREIRA, G. F. P.; LEMOS, O. L. Sensor ativo como ferramenta de estimativa de nitrogênio e clorofila em variedades de café **SBICafé**. 2019
- LIMA, L. M. D.; POZZA, E. A.; TORRES, H. N.; POZZA, A. A.; SALGADO, M.; PFENNING, L. H. Relação nitrogênio/potássio com mancha de Phoma e nutrição de mudas de cafeeiro em solução nutritiva. *Tropical Plant Pathology*, 35, 223-228. 2010
- OLIVEIRA, I.V.; ROSA, D.P; GERARDI, J.S. VARIAÇÃO ESPACIAL DA COMPACTAÇÃO DO SOLO NO TEOR DE CLOROFILA NA CULTURA DO MILHO. **Convibra**. Disponível em : [https://convibra.org/congresso/res/uploads/pdf/artigo\\_17753\\_2020124011.pdf](https://convibra.org/congresso/res/uploads/pdf/artigo_17753_2020124011.pdf) 2022.
- OLIVEIRA, A. P. P. de.; LIMA, E.; ANJOS, L. H. C. dos.; ZONTA, E.; PEREIRA, M. G. Sistemas de colheita da cana-de-açúcar: Conhecimento atual sobre modificações em atributos de solos de tabuleiro. **Revista Brasileira de Engenharia Agrícola e Ambiental**. Campina Grande-PB, v.18, n.9, p.939–947, 2014
- PETRIM, I. C.; ALMEIDA, G. R. R. Avaliação do teor de clorofila em lavoura cafeeira podada e em produção e em diferentes exposições ao sol. **Revista Agroveterinária do Sul de Minas - ISSN: 2674-9661**, v. 2, n. 1, p. 53 - 64, 22 jun. 2020.
- RODRIGUES, Z. G.; ALMEIDA, G. R. R; DA CUNHA, L.T. importância de fungicidas na desfolha, produção e retenção de frutos do cafeeiro. **Revista Agroveterinária do Sul de Minas - ISSN: 2674-9661**, v. 1, n. 1, p. 55 - 61, 8 out. 2019.
- SOUSA, D. S.; LADEIA, C. A.; FREIRE, D. S.; DOS SANTOS, J. R. E.; LEMOS, O. L. Relação entre o índice de clorofila e as faces de exposição solar no cafeeiro. *Semana de Agronomia da UESB (SEAGRUS)-ISSN 2526-8406*, 2(1). (2020)
- SPERANZA, E. A.; GREGO, C. R.; RODRIGUES, G. C.; LUCHIARI JUNIOR, A. Influência das diferentes faces de exposição ao sol nos índices vegetativos e relativo de clorofila em cafés especiais. In *Embrapa Agricultura Digital-Artigo em anais de congresso (ALICE)*. In: **Congresso Brasileiro de agroinformática**, 12., 2019, Indaiatuba. Anais... Ponta Grossa: SBIAGRO, 2019.
- VARGAS, J. P. R. ; BOLZAN, L.J. ; GUIMARÃES, G.P. ; MENDONÇA, E.S. Densidade e Resistência do Solo a Penetração Sob Cultivo de Cafeeiro Agroflorestal e Convencional. **Congresso Brasileiro de Ciências do solo**. Ago. 2013.

## PERÍODO ÓTIMO DE COLHEITA DE MANDIOCA DEFINIDO A PARTIR DE INFORMAÇÕES DE SENSOR EMBARCADO EM VANT

RONILSON DE SOUZA SANTOS<sup>1</sup>; BRENO DA SILVA SANTOS<sup>2</sup>; RADMIR DA SILVA ARAÚJO<sup>3</sup>; DJAIR ALVES MOREIRA<sup>4</sup>; GIOVANNI STEFANO GOMES DE SOUSA<sup>5</sup>

<sup>1</sup>Engenheiro Agrônomo, Professor Adjunto IV - Faculdade de Engenharia Agrônômica, UFPA, Campus de Altamira. rssantos@ufpa.br / (93) 9 8123-0266; <sup>2</sup>Estudante, Graduando em Engenharia Agrônômica - Faculdade de Engenharia Agrônômica, UFPA, Campus de Altamira; <sup>3</sup>Estudante, Graduando em Engenharia Agrônômica - Faculdade de Engenharia Agrônômica, UFPA, Campus de Altamira; <sup>4</sup>Engenheiro Agrônomo, Professor Associado IV - Faculdade de Engenharia Agrônômica, UFPA, Campus de Altamira; <sup>5</sup>Estudante, Graduando de Engenharia Agrônômica - Faculdade de Engenharia Agrônômica, UFPA, Campus de Altamira

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** A mandioca, originária do Brasil, é cultivada praticamente em todo seu território, destacando-se como um dos principais alimentos produzidos e consumidos. A realização da colheita em função de um período médio, não é um método exato, podendo levar a realização de uma colheita precoce ou tardia. O objetivo deste trabalho foi determinar o período ótimo de colheita da mandioca, baseando-se no comportamento espectral da cultura, utilizando sensores passivos, embarcados em veículo aéreo não tripulado. O experimento foi conduzido de junho de 2020 a agosto de 2021, no município de Altamira-PA. A unidade experimental foi composta de 1 hectare, dividida em 60 grades regulares, medindo 12,90 m x 12,90 m. A cada 30 dias, foram realizados sobrevoo sobre a área experimental com drone equipado com um par de sensores ópticos. Concomitante a cada voo, realizava-se a colheita das raízes, em três pontos aleatórios, em cada uma das grades, as quais tinham o centro georreferenciado, cuja finalidade foi efetuar a análise geoespacial dos dados coletados. As informações agrônômicas coletadas e avaliadas foram a produtividade, altimetria do terreno, desidade do solo, NDVI e SAVI. Os dados foram processados no software de análise geoestatística GS<sup>+</sup>. A produtividade média do período analisado foi de 22,8 t.ha<sup>-1</sup>. A densidade do solo variou de 1,21 a 1,97 g.cm<sup>-3</sup>, sendo considerada desfavorável para o cultivo da mandioca. Os IV's, em todo o período avaliado, variaram de 0,28 a 0,45 e 0,20 a 0,38 SAVI e NDVI, respectivamente, os quais foram considerados baixos, injeando que a cultura estava vegetando sob algum tipo de estresse. Quando comparado ao NDVI, o SAVI se mostrou mais responsivo como ferramenta para as avaliações agrônômicas propostas com a cultivar utilizada neste experimento. Não foi possível definir o período ótimo de colheita da cultura, com os dados coletados até o 20º mês.

**PALAVRAS-CHAVE:** NDVI; rendimento da cultura; mandioca

## OPTIMAL PERIOD TO CASSAVA HARVEST, BASED IN SENSOR INFORMATION BOARDED IN UAV

**ABSTRACT:** Cassava, originally from Brazil, is cultivated practically in all over his territory, being as one of the main foods produced and consumed. However, the harvesting according to an average period is not an exact method, and may take to an early or late harvest. The objective of this work was to determine the optimal period for cassava harvest, based on the spectral behavior crop, using passive sensors onboarded on an unmanned aerial vehicle. The field activities was conducted in Altamira county- PA, from June 2020 to August 2021. The experimental unit consisted of 1 hectare, divided into 60 regular grids, measuring 12.90 m x 12.90 m. Every 30 days, was made overflights in the experimental area, using a DRONE equipped with a pair of optical sensors. Following each flight, the roots were harvested at three random points in each grid, which had the center georeferenced, whose purpose was to carry out the geospatial analysis of the collected data. The agronomic information collected and evaluated were crop yield, terrain altimetry, bulk density, NDVI and SAVI. The data were processed in the GS<sup>+</sup> geostatistical analysis software. The average productivity of the analyzed period was 22.8 t.ha<sup>-1</sup>, and bulk density ranged from 1.21 to 1.97 g.cm<sup>-3</sup>, being considered unfavorable for the cassava crop. The VI's, throughout the evaluated period, ranged from 0.28 to 0.45 and 0.20 to 0.38 SAVI and NDVI, respectively, which were considered low, indicating that the crop was vegetating under some

kind of stress. Compared to NDVI, the SAVI was more responsive as a tool for the proposed agronomic evaluations with the cultivar used in this experiment. Nevertheless, it was possible to determine the optimal crop harvest period, with the analysis performed with the data collected until the 20<sup>th</sup> month.

**KEYWORDS:** NDVI; crop yield; cassava

**INTRODUÇÃO:** De acordo com a FAO, o Brasil é o quinto maior produtor mundial de cultura, com 17,64 milhões de toneladas, com a maior produção advinda de pequenas propriedades rurais. É uma cultura rústica, de boa capacidade de produção, mesmo em condições adversas (FIALHO et al., 2011). O estado do Pará figura-se como o maior produtor brasileiro, com safra estimada em 3,9 milhões de toneladas, mas a sua produtividade é baixa, não superando as 14 t.ha<sup>-1</sup>, com plantio utilizando o sistema denominado de corte e queima (CHAVES, 2016).

A partir da filosofia de gerenciamento de produção agrícola denominada de Agricultura de Precisão, a qual tem como princípio básico a análise da variabilidade espacial dos atributos edafoclimáticos e produtividade da área cultivada, possibilitando realizar ações agronômicas de forma assertiva, otimizando o uso dos insumos. Dentre suas vertentes, há a análise espacial das áreas cultivadas, a partir de imagens obtidas com sensores passivos ou ativos, embarcados em diversas plataformas de transporte. Inclusive, em veículos aéreos não tripulados, a um custo acessível, se comparado com as missões realizadas com os sensores embarcados em aeronaves tripuladas. Ademais, de acordo com Linhares (2016), de forma complementar, vem sendo utilizado no monitoramento das atividades agrícolas.

De acordo com Moraes (2002) uma planta saldável, em plena atividade fotossintética, tende a absorver os comprimentos de onda na faixa do visível e refletir fortemente no infravermelho próximo. Por outro lado, plantas sob estresse refletem mais a luz visível e menos a luz do infravermelho próximo (RODRIGUES et al. 2013). Isso ocorre pelo fato da existência de uma camada esponjosa, denominada de parênquima, que desintegra-se e a planta deixa de refletir o máximo de luz *NIR*, aumentando a quantidade de luz vermelha refletida.

Ponzoni e Shimabukuro (2010) relataram que as plantas têm assinatura espectral característica na faixa do espectro eletromagnético e utilizam valores compreendidos entre 390 a 790 nm, contemplando a faixa do visível e 760 nm a 1300 nm sendo a faixa do infravermelho próximo (HOLM et al. 1987).

A partir de combinações aritméticas de duas ou mais bandas espectrais, há a possibilidade de definir índices que permitem fazer inferências agronômicas, relativas ao estado vegetativo da cultura. Entre estes índices, o mais popular é o Índice de Vegetação Normalizada- NDVI e o Índice de Solo e Vegetação Ajustada-SAVI (MATSUSHITA et al., 2007), com valores variando de -1 a 1. Sendo que, quanto maior for o valor obtido, maior será a probabilidade que seja referente a uma área com vegetação saudável e maior vigor de desenvolvimento da cultura (ROUSE et al., 1973) enquanto que o valor zero se refere aos pixels não vegetados (LINHARES 2016). Por tanto o objetivo deste trabalho é determinar o período ótimo de colheita da mandioca através do comportamento espectral da cultura, utilizando sensores passivos, embarcados em veículo aéreo não tripulado.

**MATERIAIS E MÉTODOS:** O trabalho foi conduzido em uma área agrícola no município de Altamira-PA, localizado sob as coordenadas 3°08'14" S e 52°16'14" W, com altitude média de 149 metros. A área constou com 1 hectare de mandioca da variedade BRS Tapioqueira de ciclo longo.



**Figura 1.** Mapa de situação e localização da área experimental.

O plantio foi realizado no mês de janeiro de 2020, utilizando plantadora mecanizada, obedecendo o espaçamento de 1,0 x 1,0 m, entre linhas e entre plantas, respectivamente, totalizando um stand de 10.000 plantas por hectare. Para as análises agronômicas, foram considerados a produtividade da cultura, altimetria do terreno, densidade do solo, *NDVI* e *SAVI*.

Baseando-se na metodologia de Pola et al., (2020), realizava-se mensalmente a colheita da cultura. Para tal, era procedido o arranquio das raízes, com a obtenção da massa fresca em cada grade amostral.

Para obter a densidade do solo, realizou-se uma coleta de amostras indeformadas, na profundidade de 0,0 a 0,20 m. E, seguindo a metodologia da EMBRAPA (2017), as mesmas foram analisadas no Laboratório de Mecanização Agrícola e Agricultura de Precisão- LAMAP da Universidade Federal do Pará.

Exceto para a altimetria, que teve como referência a altitude ortométrica, obtida no centro de cada grade amostral, as demais variáveis citadas eram coletadas, aleatoriamente, em seis pontos distintos, dentro de cada uma das 60 grades amostrais da unidade área experimental.

Para avaliação do comportamento dos IV's, baseando-se na metodologia de Jacintho (2014), a partir dos 6 meses após o plantio, concomitante a cada colheita, utilizando uma Aeronave Remotamente Pilotada- *RPA*, equipada com câmera digital capaz de captar imagens no espectro do visível e infravermelho próximo, foi iniciada a coleta de informações na área experimental, com sobrevoos realizados a cada 30 dias, sempre ao meio dia, momento em que o sol estaria no *Zenith* do local, evitando assim o sombreamento do dossel da cultura.

A aeronave utilizada foi de asa móvel Marca/modelo 3DR Solo, equipada com um par de câmeras digitais, capazes de captar imagens no espectro do visível (*RGB*) e Infravermelho Próximo (*Near Infrared*), ambas Marca/Modelo *Mapir Survey 3*, interligadas a receptores de sinal de *GPS* para aquisição das coordenadas de cada imagem.

Para manter a regularidade dos voos, os sobrevoos foram programados no software livre *Mission Planner*, versão 1.3.53, com os seguintes parâmetros: velocidade de deslocamento de 8 m.s<sup>-1</sup>, altitude de 60 m e sobreposição de imagens de 80% e 60% na longitudinal e lateral, respectivamente, sendo estes parâmetros gravados na controladora de voo da aeronave.

As imagens coletadas foram processadas no software *Agisoft Metashape* versão 1.5.4 para obtenção das imagens no comprimento de onda situados entre 0,63 e 0,700  $\mu\text{m}$  (*RED*) e 0,725 a 1,30  $\mu\text{m}$  (*NIR*)

Utilizando o comprimento de onda do *RED* e *NIR*, conforme descreveu Sakamoto et al., (2011) foi calculado o *NDVI* utilizando a Equação 1, e o Índice de Vegetação Ajustado ao Solo (*SAVI*), a partir a Equação 2, permitido gerar a planta de variabilidade espacial dos citados índices

$$\text{NDVI} = \frac{\text{NIR} - \text{RED}}{\text{NIR} + \text{RED}} \quad (\text{Equação 1})$$

Onde,

NDVI= Índice de vegetação normalizada;

NIR = Refletância do infravermelho próximo;

RED = Refletância da faixa do vermelho do espectro visível.

$$SAVI = \frac{NIR - RED}{NIR + RED} \times (1 + L) \quad (\text{Enquação 2})$$

Onde,

SAVI= Índice de vegetação Ajustado ao Solo;


NIR = Refletância do infravermelho próximo;

RED = Refletância da faixa do vermelho do espectro visível;

L= 0,5

**RESULTADOS E DISCUSSÃO:** A produtividade média para o período avaliado que foi de 22,8 t.ha<sup>-1</sup>, está em conformidade com as informações de EMBRAPA (2017). No entanto, bem distante dos resultados citados por e Souza et al (2020) e Gonçalves et al (2021) que obtiveram produtividades de 36 t.ha<sup>-1</sup> e 41 t.ha<sup>-1</sup>, respectivamente. Portanto, concluindo-se que a cultura não expressou toda sua capacidade produtiva.

A altimetria na área de estudo variou de 136 a 143 m (Figura 2) correspondendo a uma declividade de média de 7%, classificada como suave ondulado (EMBRAPA, 2009) condição que, pode concorrer para o desencadeamento da erosão do solo cultivado (SILVA, 2021) que, se mais acentuada, pode incidir, diretamente na infiltração de água (Garcia et al. 2020), arraste de nutrientes e partículas (VIEIRA et al., 2020) que, em última análise, de acordo com Iori et al., (2014) pode refletir diretamente nas dinâmicas fisiológicas e anatômicas da cultura.

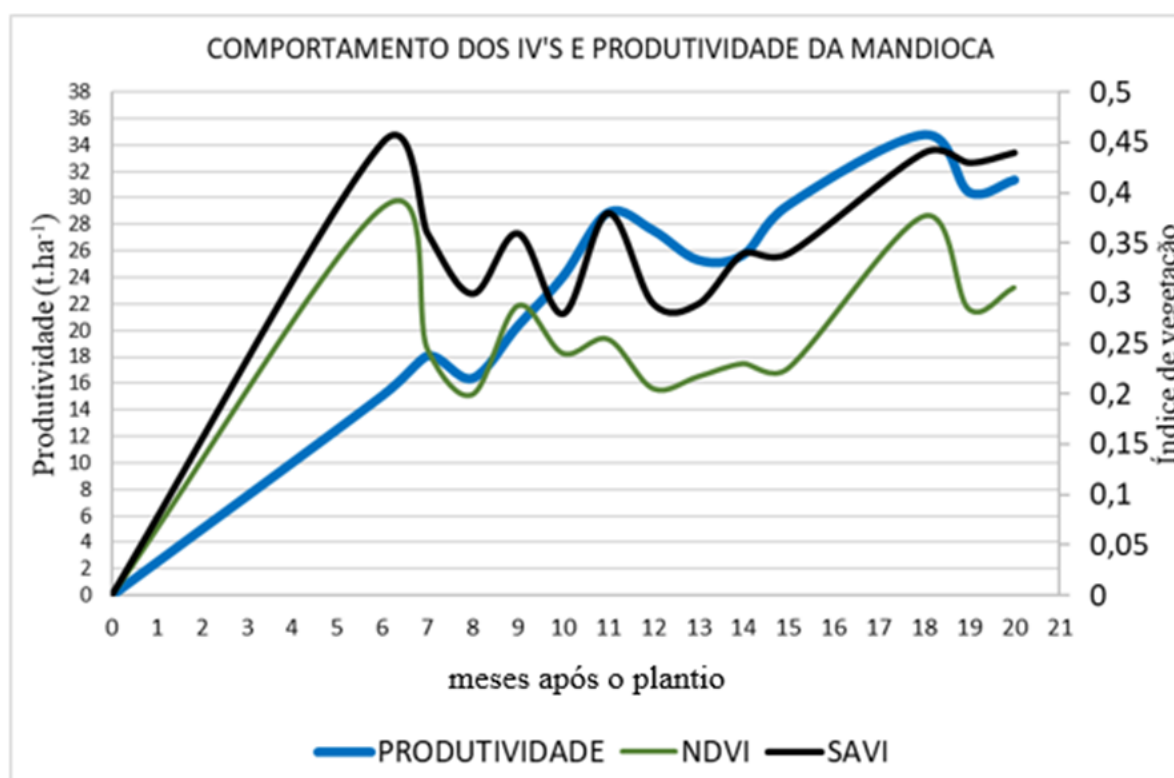




**Figura 2.** Planta de variabilidade espacial da altimetria.

A densidade do solo variou de 1,46 a 1,97 g.cm<sup>3</sup>. E, baseando-se nos resultados obtidos por Reicher et al. (2003) são níveis que desfavorecem o desenvolvimento das raízes, condição que é confirmada por Argenton et al., (2005) que constataram que em Latossolo Vermelho argiloso, a deficiência de aeração inicia-se com densidade do solo próximo de 1,30 g.cm<sup>-3</sup>.

Considerando os IV's gerados, observa-se que o SAVI obteve resultados superiores, quando comparado àqueles de NDVI (Figura 1). Sobre isto, baseando-se em Huete (1988), pode-se inferir que a causa deste comportamento pode ter sido em função da minimização ruído do sinal emitido pelo solo, a partir da incorporação do fator L na equação geradora do índice em questão. Fato que também está em conformidade com os resultados do trabalho de Araújo et al., (2018), que analisaram os índices de vegetação em Mossoró- RN, e obtiveram resultados de NDVI menores que os valores de SAVI.



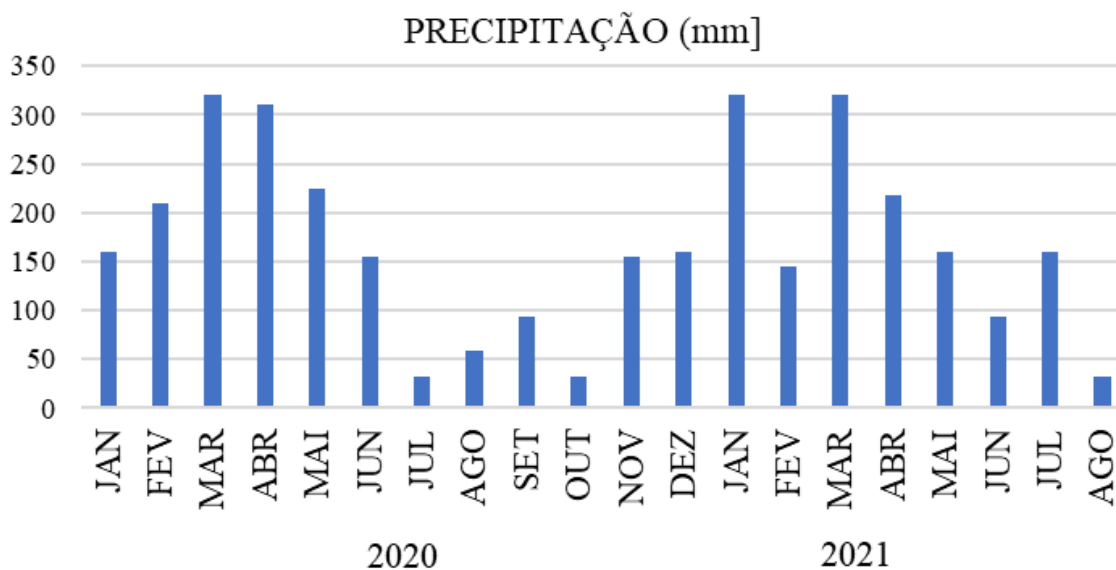
**Figura 3.** Comportamento dos Índices de Vegetação e produtividade da cultura da mandioca, em função da variação espaço temporal.

Os resultados dos índices, em todo o período avaliado, foram considerados baixos, com as médias de NDVI e SAVI de 24 e 32, respectivamente, ensejando que a planta estava vegetando sob algum tipo de estresse.

Na análise temporal (Figura 3), observa-se a dinâmica da produtividade, NDVI e SAVI entre os meses avaliados. Iniciando-se no mês de junho, com a predominância do SAVI sobre o NDVI de 0,45 e 0,38, respectivamente, mas ocorrendo redução nos meses de julho e agosto. Esta redução pode estar diretamente relacionada com a evolução do período climático regional, denominado verão amazônico (Figura 2), que inicia no mês de maio e estende-se até o mês de dezembro.

Observa-se na figura 4, que a partir do mês de dezembro, com o início da estação chuvosa, os valores de NDVI e SAVI iniciam o incremento positivo, coincidindo com as maiores produtividades. Fator esse que, baseando-

se em Duarte (2012) tem relação direta com dinâmica fisiológicas e anatômicas da cultura.



**Figura 4:** Gráfico de precipitação pluviométrica, da cidade de Altamira-PA, entre os anos de 2020 e 2021. Fonte: Instituto Nacional de Meteorologia – INMET (2021).

Os resultados referentes à análise geostatística dos fatores avaliados na área experimental, estão contidos na Tabela 1. O SAVI e a densidade do solo tiveram baixa dependência espacial ( $IDE \leq 25\%$ ) de 6,626 e 11,111, respectivamente. A produtividade média do período avaliado apresentou moderada dependência espacial-IDE de 67,359, e as demais variáveis apresentaram forte dependência espacial ( $IDE \geq 75\%$ ), conforme a classificação de Zimback (2001).


**TABELA 1.** Parâmetros dos semi variogramas, ajustados para o NDVI, SAVI, produtividade, altimetria e densidade do solo, obtidos no cultivo de mandioca.

Variável avaliada	Modelo	Alcance (a)	Patamar (Co+ C)	Efeito Pepita (Co)	IDE	r <sup>2</sup>
NDVI	Linear	137.31	0,009	0,001	88,888	0,979
SAVI	Linear	158.00	0,0332	0,031	6,626	0,968
Produtividade média (t.ha <sup>-1</sup> )	Linear	120,24	0,674	0,220	67,359	0,988
Altimetria (m)	Gaussiano	120,79	3.237	0,805	99,975	0,991
Densidade do solo (g.cm <sup>3</sup> )	Linear	69,937	0,009	0,008	11,111	0,840

IDE = índice de dependência espacial; r<sup>2</sup> = coeficiente de determinação.

Exceto pela altimetria, todos os fatores analisados obtiveram os melhores ajustes utilizando o modelo Linear. E, exceto na densidade do solo, todas as variáveis tiveram dependência espacial a uma distância máxima de 120 m.

No comportamento da validação cruzada, apresentado na Figura 4, observa-se uma pequena diferença entre os valores reais para os valores estimados, havendo uniformidade na distribuição dos pontos ao longo das retas, sendo esta situação muito próxima àquela desejada na validação cruzada, podendo inferir que houve uma boa estimativa dos resultados obtidos.



**Figura 5.** Validação Cruzada a) NDVI, b) SAVI, c) Produtividade média, d) Altimetria e) Densidade do solo.

**CONCLUSÃO:** Em virtude de fatores edafoclimáticos, a cultura não pode expressar o seu máximo potencial genético, ocasionando baixa produtividade.

Pode se considerar os resultados de densidade do solo como desfavoráveis para a cultura, condição que refletiu nos baixos resultados dos IV's, durante o período avaliado.

Quando comparado ao *NDVI*, o *SAVI* foi mais responsivo para as avaliações agrônômicas propostas com a cultivar utilizada neste experimento.

Não foi possível definir o período ótimo de colheita da cultura, durante o tempo de condução do experimento.

#### **AGRADECIMENTOS:**

Ao LAMAP-FEA-UFGA-Altamira, ao Sítio Santo Antônio, ao CNPq e a PROPESP-UFGA, pelo apoio logístico e financeiro dispensado para a realização deste trabalho.

#### **REFERÊNCIAS**

ARAÚJO, A.B.A.; FREITAS, I.A.S.; JUNIOR, A.A.C.; SILVA, S.L.; SILVA, P.C.M. Análise dos índices de vegetação *NDVI* e *SAVI* no município de Mossoró utilizando imagens Landsat 8, **In. III Congresso Internacional das Ciências Agrárias**, 2018.

ARGENTON, J.; ALBUQUERQUE, J. A.; BAYER, C.; WILDNER, L. P. Comportamento de atributos relacionados com a forma da estrutura de Latossolo Vermelho sob sistemas de preparo e plantas de cobertura. **Revista Brasileira de Ciência do Solo**, 29:425-435, 2005.

BENESI, I.R.M. et al. *The effect of genotype, location and season on cassava starch extraction*. **Euphytica**, v. 160, p. 59-74. 2008.

CHAVES, R. S.. **Tipos de solo e a orientação para o mercado influenciam na escolha das variedades de mandioca (*Manihot esculenta* Crantz) nos sistemas de produção do baixo rio Tapajós**, Pará. Dissertação (Mestrado em Botânica) - Instituto Nacional de Pesquisas da Amazônia, Manaus, 2016.

SILVA, B.D. **Caracterização fisiográfica de bacia hidrográfica localizada no município de Russas/Ce**. Trabalho de Conclusão de Curso, Instituto Federal Goiano, Goiás, 2021.

DUARTE, A.L.M. Efeito da água sobre o crescimento e o valor nutritivo das plantas forrageiras. **Pesquisa e Tecnologia**, v.9, p.1-6, 2012.

EMBRAPA-EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. Centro Nacional de Pesquisa de Solos (Rio de Janeiro, RJ). **Sistema brasileiro de classificação de solos**. 2009.

EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária. **Recomendações de adubação e calagem para o estado do Pará**. EMBRAPA, 2017.

FAO. *Faostat database gateway*. 2016. Disponível em: <<http://faostat.fao.org/site/567/DesktopDefault.aspx?PageID=567#ancor>>. Acesso em: 5 de Dez. 2020.

FIALHO, J. F.; VIEIRA, E. A. **Manejo do Solo no Cultivo de Mandioca. Mandioca no cerrado: orientações técnicas**. Planaltina: Embrapa Cerrados, 2011.

GARCIA, Y. M., CAMPOS, S., TAGLIARINI, F. S. N., CAMPOS, M., RODRIGUES, B. T. (2020). Declividade e potencial para mecanização agrícola da bacia hidrográfica do Ribeirão Pederneiras - Pederneiras-SP. *Bioeng - Revista Brasileira de Engenharia de Biosistemas*, 14(1), 62-72.

GONÇALVES, Z. S. et al. Avaliação agrônômica e qualidade de farinha em cultivares de mandioca sob condições de campo. *Journal of Biotechnology and Biodiversity*, v. 9, n. 2, p. 192-200, 2021.

HOLM, A. M.; BURNSIDE, D. G.; MITCHELL, A. A. O desenvolvimento de um sistema para monitorar a tendência das condições de alcance nos arbustos áridos da Austrália Ocidental. *The Rangeland Journal*, v. 9, n. 1, p. 14-20, 1987.

HUETE, A. R. A Soil-Adjusted Vegetation Index (SAVI). *Remote Sensing of Environment*, v. 25, n. 3, p.205-309, Aug. 1988.

IORI, P. et al. Influence of field slope and coffee plantation age on the physical properties of a red-yellow latosol. *Revista Brasileira de Ciência do Solo*, 38 (1): 107-117, 2014.

Instituto Nacional de Meteorologia: Estação Meteorológica de Altamira A-253. Dados meteorológicos do ano de 2020 a 2021. Disponível em <https://tempo.inmet.gov.br/PrecAcumulada> acessado em 28 de março de 2022.

JACINTHO, J. L. et al. Utilização de veículo aéreo não tripulado (VANT) na geração de mapa de uso do solo para agricultura de precisão. **In:** Congresso Brasileiro de Agricultura de Precisão. 2014, São Pedro-SP, Anais .... São Pedro: SBEA, 2014.

KLEIN, V. A. Densidade relativa: Um indicador da qualidade física de um Latossolo Vermelho. **R. Ci. Agron.**, 5:26-32, 2006.

LINHARES, M. M. de A. **Uso de veículo aéreo não tripulado na determinação de índice de vegetação em área de pastagem em Nova Mutum-MT**. 2016. 119 f. Dissertação (Mestrado em Geografia) - Universidade Federal de Goiás, Instituto de Geografia, Goiânia, 2016.

MATSUSHITA, B. et al. Sensibilidade do Índice de Vegetação Avançada (EVI) e Índice de Vegetação de Diferença Normalizada (NDVI) aos Efeitos Topográficos: Um Estudo de Caso na Floresta de Cipreste de Alta Densidade. **Sensores (Basileia)**. v. 7 n.1, p: 2636- 2651. 2007.

MORAES, E. C. de. **Fundamentos de sensoriamento**. São José dos Campos. INPE. 23p. 2002.

POLA, A.C.; NUNES, E.C.; MORETO, A.L. Matéria seca em raízes de mandioca determinada pelos métodos da balança hidrostática e de secagem em estufa. **Agropecuária Catarinense**, Florianópolis, v.33, n. 1, p. 56-60, 2020.

PONZONI, F. J; SHIMABUKURO, Y. E. **Sensoriamento Remoto no estudo da vegetação**. São José dos Campos: A Silva Vieira Ed., 136p. 2010.

REICHERT, J. M.; SUZUKI, L. E. A. S.; REINERT, D. J. Compactação do solo em sistemas agropecuários e florestais: identificação, efeitos, limites críticos e mitigação. **Tópicos Ci. Solo**, Viçosa, v.5, p.50-121, 2007.

REINERT, D. J.; REICHERT, J. M.; SILVA, V. R. Propriedades físicas de solos em sistema plantio direto irrigado. **In:** CARLESSO, R.; PETRY, M. T.; ROSA, G. M.; CERETTA, C. A. Irrigação por aspersão no Rio Grande do Sul. p.114-133, Santa Maria, 2001.

RODRIGUES, T. S.; RIBEIRO, S. R. A.; VAZ, M. S. M. G. Avaliação do desempenho de dois Índices de Vegetação (*NDVI e SAVI*) por meio de Índice de Qualidade de Imagens. **In:** XVI Simpósio Brasileiro de Sensoriamento Remoto. 2013. Foz do Iguaçu. Anais.... Foz do Iguaçu: INPE, 2013.

ROUSE, J. W., HAAS; R. H., SCHELL, J.A.; DEERING, D. W. *Monitoring vegetation systems in the Great Plains with ERTS, Third ERTS Symposium, NASA SP-351 I*, 309- 317, 1973.

SOUZA, E. D.; DE LIMA, H. E. BRS Caipira e BRS Tapioqueira: Novas Cultivares de Mandioca de Indústria para Cultivo em Roraima. **Embrapa Roraima-Comunicado Técnico (INFOTECA-E)**, 2017.

SOUZA, E. D. Avaliação de mandioca de indústria em área de Cerrado em Roraima. 2021

VIEIRA, Z. C.; ALMEIDA, K. S.; ALBUQUERQUE, E. F. Influência de telhados verdes pré-moldados na redução e retardo do escoamento em precipitações intensas. *Brazilian Journal of Animal and Environmental Research*,3(3), (2020).

ZIMBACK, C. R. L. **Análise espacial de atributos químicos de solos para fins de mapeamento da fertilidade**. Botucatu, 2001. 114f. Tese (Livre-Docência em Levantamento do solo e foto pedologia) - Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, 2001.

# ALTERAÇÃO DA DENSIDADE DO SOLO POR OPERAÇÕES AGRÍCOLAS MECANIZADAS: INTERAÇÃO ENTRE AMBIENTE E EQUIPAMENTO

Vinícius Grillo<sup>1</sup>; Alessandro Alvarenga Pereira da Silva <sup>2</sup>; Matheus Gabriel Acorsi<sup>2</sup>; Leandro Maria Gimenez<sup>3</sup>

<sup>1</sup>Engenheiro Agrônomo, Graduando - Dpto. Engenharia de Biossistemas, ESALQ, USP, Piracicaba - SP. [viniciusgrillo@usp.br](mailto:viniciusgrillo@usp.br) / (19) 9 7144-2846; <sup>2</sup>Engenheiro Agrônomo, Doutorando - Dpto. Engenharia de Biossistemas, ESALQ, USP, Piracicaba - SP; <sup>3</sup>Engenheiro Agrônomo, Professor - Dpto. Engenharia de Biossistemas, ESALQ, USP, Piracicaba - SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** O uso intensivo das áreas agrícolas usualmente requer operações mecanizadas mais rápidas com elevação da potência e consequente aplicação de maiores cargas sobre o solo. O aumento da densidade do solo compactação restringe a produtividade dos cultivos. A correta seleção dos equipamentos e o seu uso em condições satisfatórias de umidade do solo permite minimizar a compactação. Modelos para predição da capacidade dos solos em suportar cargas e dos efeitos das cargas sobre suas características estão disponíveis, mas vem sendo usualmente empregados sem considerar a variabilidade do solo. Neste trabalho levantou-se as principais características de tratores de rodas representativos de três faixas de potência, 73 kW, 183 kW e 320 kW (classes II, IV e V, respectivamente) e de semeadoras empregados no Brasil. Simulou-se os efeitos do tráfego em gleba de solo com variabilidade em sua composição granulométrica. Os resultados demonstraram que as pressões aplicadas pelos rodados dianteiros oscilaram entre 244 e 320 kPa, e pelos traseiros, entre 264 e 327 kPa. Os efeitos na densidade do solo oscilaram em função da sua granulometria, com intensidades e profundidades de alterações variando espacialmente. O trator da maior faixa de potência provocou alteração na densidade do solo até a profundidade de 0,30 m. O trator da classe II apresentou maior percentual de área pisoteada por rodados, entretanto com danos na estrutura do solo foram restritos à camada 0-0,10 m. A regionalização das porções mais suscetíveis e a compreensão do tipo de dano são relevantes no planejamento das operações visando minimizar os efeitos e também à sua correção de modo localizado.

**PALAVRAS-CHAVE:** área pisoteada por rodados; capacidade de suporte do solo; simulação

## CHANGE IN SOIL BULK DENSITY BY MECHANIZED AGRICULTURAL OPERATIONS: INTERACTION BETWEEN ENVIRONMENT AND EQUIPMENT

**ABSTRACT:** The intensive use of agricultural land usually requires the intensification of mechanized operations, demanding more powerful equipment which ultimately lead to heavier load traffic. As a result, soil density tends to increase due to soil compaction, reducing crop yield. The correct selection of equipment and adoption of traffic limitations imposed by soil moisture conditions are key to minimize soil compaction. Models for predicting soil load capacity and the effect of different loads on soil physical properties are available, but they are usually used without considering soil spatial variability. In this work, we considered the main characteristics of wheeled tractors represented by three engine power classes, 73 kW, 183 kW and 320 kW (classes II, IV and V, respectively) along with seeders used in Brazil. Traffic effects were simulated considering soils with different granulometric composition. The results showed that the pressures applied by the front wheels varied from 244 to 320 kPa, and by the rear wheels it varied from 264 to 327 kPa. The effects on soil density fluctuated as a function of granulometry, with intensities and depths of structural alterations varying spatially. The tractor with the highest engine power class caused a change in soil density up to a depth of 0.30 m. The class II tractor showed the highest percentage of trampled area by wheels, however with damage to the soil structure, they were restricted to the 0-0.10 m layer. The delineation of the most susceptible portions of the field and the understanding of damage extension are relevant in operations planning in order to minimize the effects and also to correct them implementing site-specific management practices.

**KEYWORDS:** trampled area by wheels; soil load capacity; simulation model

**INTRODUÇÃO:** A agricultura moderna e intensiva requer o emprego da mecanização. A compactação do solo é uma consequência do uso de máquinas enfrentada em diversos sistemas de produção e estima-se que cerca de 680.000 km<sup>2</sup> de solos ao redor do planeta estejam com este problema (DIAS, 2016). A necessidade de aumentar a produtividade das culturas e eficiência de trabalho requer intensificação da mecanização com elevação do tamanho dos maquinários utilizados nas operações, os quais estão cada vez mais pesados e mais potentes (MCPHEE et al., 2020).

A compactação do solo limita o desenvolvimento das raízes das plantas (BENGOUGH et al., 2006) devido à maior densidade aparente do solo, resistência à penetração das raízes e menor permeabilidade ao ar e à água (HAMZA; ANDERSON, 2005). A aeração, a dinâmica hídrica, a ciclagem de nutrientes e a produtividade das culturas tendem a estabilizarem em patamar ou diminuir pelo menor volume do solo explorado devido ao impedimento físico para o desenvolvimento radicular (KELLER et al., 2019). Além disso, a compactação provoca o aumento do escoamento superficial em razão da menor porosidade e taxa de infiltração. Em casos mais severos, o risco de erosão hídrica e eólica é aumentado (HORN et al., 1995).

Há maneiras de mitigar esta perturbação mecânica do solo em sistemas de cultivo por meio da minimização, que consiste em evitar ou reduzir o tráfego quando o solo está mais suscetível à compactação; e pelo uso de equipamentos mais adequados como pneus de baixa pressão ou esteiras, a fim de reduzir os impactos. Outra alternativa é a remediação, baseada no uso de culturas com sistema radicular que tenham capacidade de penetração no solo para aliviar os efeitos da compactação, sendo esta técnica antiga e muito pesquisada nos dias atuais; também pode ser adotada a estratégia do confinamento, com uso de tráfego controlado, de modo que as máquinas passem sempre pelo mesmo local, isolando a compactação e preservando maior proporção de solo não impactado pelo trânsito (MCPHEE et al., 2020).

Com o avanço da agricultura de precisão, uso de sistemas de direcionamento de máquinas, aplicação de ferramentas de sensoriamento e com a modelagem da compactação, abrem-se oportunidades para quantificar as distribuições espaciais e temporais da compactação do solo e seu manejo visando a otimização do sistema solo-máquina-sistema de produção (SHAHEB; VENKATESH; SHEARER, 2021).

Este trabalho busca trazer uma contribuição no entendimento do fenômeno da compactação em áreas agrícolas com variabilidade do solo, considerando os principais tipos de equipamentos utilizados em uma operação muito relevante para a agricultura brasileira. Por meio do levantamento dos equipamentos utilizados e da simulação do emprego dos mesmos em uma área representativa, foi verificado seu efeito como o montante de área pisoteada, as cargas aplicadas e alterações na densidade do solo.

## **MATERIAIS E MÉTODOS: Área experimental**

Em uma gleba cujo solo é classificado como Latossolo Vermelho, com textura franco arenosa, situada no município de Rondonópolis, estado de Mato Grosso, foi estabelecida uma malha com 90 pontos espaçados em 30 m, definindo uma forma retangular com 15 pontos em sua maior dimensão e seis pontos na menor, apresentado na Figura 1. Para determinação da composição granulométrica foram coletadas amostras deformadas nas camadas entre 0 a 0,2 m e 0,2 a 0,4 m; três subamostras para compor uma amostra foram coletadas em cada ponto e camada. Para determinação da granulometria foi utilizado o método do densímetro (CAMARGO et al., 2009), obtendo as frações areia (0,05 a 2,0 mm), silte (0,002 a 0,005 mm) e argila (< 0,002 mm).

### **Densidade do solo**

Por meio do uso de uma função de pedotransferência (BENITES et al., 2007), e utilizando os resultados das análises nos pontos coletados obteve-se a densidade do solo (Ds), com base no teor de argila, Equação 1.

$$D_s = 1,5224 - 0,0005 * (\text{Arg}) \quad (1)$$

onde:

Ds: Densidade do solo (Mg m<sup>-3</sup>);



Arg: Teor de argila ( $\text{g kg}^{-1}$ );

Para caracterização da Ds nas regiões delimitadas utilizou-se a média dos teores de argila na camada de 0 a 0,4 m. A consolidação das duas camadas foi adotada pois a função de pedotransferência demonstra melhor desempenho na camada de 0,1 a 0,3 m (BOSCHI et al., 2018).

### **Dimensionamento dos conjuntos trator-semeadora**

Foi realizada uma sistematização dos modelos de tratores comercializados no país com base em Quevedo (2021), e escolhido um exemplar representativo para as classes de tratores II, IV e V. Tomou-se além da potência as informações referentes aos pneus (ALAPA, 2021), e peso dos tratores considerando-se como distribuição de peso 40% do seu peso no eixo dianteiro e 60% do seu peso no eixo traseiro (SENAR, 2017) dentro de cada categoria para então selecionar os modelos. A classe II engloba os tratores com potência do motor de 37 até 73 kW de potência, sendo representada pelo modelo Massey Ferguson 4709 com 73 kW de potência. A classe IV refere-se a tratores com potência entre 110 e 183 kW e o modelo selecionado foi o Case IH Puma 230 com 177 kW de potência. Na classe V estão tratores com potência acima de 184 kW, sendo representada pelo modelo Case IH Magnum 400 com 320 kW de potência no motor. Para o dimensionamento das semeadoras, calculou-se a potência disponível na barra de tração dos três equipamentos, seguindo a metodologia expressa em ASAE (2000). A partir da potência definiu-se o número de unidades de semeadura considerando duas opções de mecanismos sulcadores para fertilizantes, discos duplos e haste. O número de unidades foi obtido pelo quociente entre a potência disponível na barra e aquela requerida para cada tipo de sulcador, resultando em 6 combinações. A largura das semeadoras foi obtida multiplicando-se o número de unidades pela distância entre unidades, considerada como 0,5 m.

### **Projeção das linhas de tráfego**

A projeção das linhas de tráfego foi realizada por meio do uso de um sistema de informações geográficas (QGIS.ORG, 2022) e utilizando os dados de largura de trabalho da semeadora. Simulou-se passadas laterais para cada combinação de fonte de potência e semeadora e calculou-se o comprimento total percorrido. A partir dos dados de largura dos pneus de cada fonte de potência calculou-se a área pisoteada e portanto sob influência do tráfego dos conjuntos.

### **Simulações da compactação do solo utilizando *soilphysics***

Para a simulação da compactação do solo foi utilizado um modelo computacional com um conjunto de funções do Software R CORE TEAM (2021), pacote *soilphysics*, com a finalidade de simular a variação da densidade do solo (LIMA; SILVA; SILVA, 2021). Foi utilizada a função *stressTraffic*, para calcular a área de contato, distribuição de tensões e propagação de tensões com base no modelo *SoilFlex* (KELLER et al., 2007). A distribuição das tensões sobre a área de contato, assumida como o limite superior, foi estimada a partir da carga da roda e das características do pneu usando o modelo proposto por KELLER (2005). A propagação da tensão até uma profundidade de 0,4 m foi simulada de acordo com Söhne (1953) usando um fator de concentração de 3 (FROHLICH, 1934), seguindo recomendação de Keller et al (2014). Os parâmetros de máquinas exigidos pelo *stressTraffic* para calcular a área de contato, tensão sobre a área de contato e a propagação estão listados na Tabela 2. Foi considerada apenas a carga aplicada pelo trator não levando em consideração a carga dinâmica ou as cargas aplicadas pelos rodados da semeadora.

Foi utilizada a função *soilDeformation*, para calcular a variação da Ds em função da tensão normal média aplicada usando a teoria do estado crítico (O'SULLIVAN; ROBERTSON, 1996). Os parâmetros mecânicos de entrada necessários,  $N$  (volume específico em  $P = 1 \text{ kPa}$ ),  $\lambda_n$  (índice de compressão) e  $k$  (índice de recompressão) foram obtidos aplicando as funções de pedotransferência desenvolvidas por Lima et al. (2018), usando como entrada a Ds média e considerando o potencial matricial de 100 hPa (correspondente à capacidade de campo). O modelo de O'Sullivan; Robertson (1996) também requer o valor do parâmetro  $k'$ , que é a inclinação da linha de recompressão mais íngreme, e  $m$ , que é a separação entre a linha de ruptura e a linha de compressão virgem (O'SULLIVAN; ROBERTSON, 1996). Utilizou-se  $k' = (\lambda_n k)^{0.5}$  e  $m = 1,3$  (O'SULLIVAN; ROBERTSON, 1996; KELLER et al., 2007). Calculou-se a variação da Ds nas profundidades de 0,05; 0,10; 0,15; 0,20; 0,30 e 0,40 m.

### **Análise estatística**

Análises descritivas foram realizadas para os atributos granulométricos (argila, silte e areia) e Ds, para representar as características do conjunto de dados obtidos no processo de amostragem. Foram obtidas média, mediana, mínimo, máximo, amplitude, quartil inferior e superior, assimetria curtose, desvio padrão e coeficiente de variação. O teste de Shapiro-Wilk foi aplicado para avaliar se os dados apresentavam distribuição normal.

### Modelagem e predição espacial

Para a representação espacial dos atributos argila e Ds, foi realizada a interpolação do conjunto de dados utilizando o software QGIS.ORG (2022). A análise geoestatística foi utilizada para caracterização da presença de dependência espacial e para geração de modelos de semavariograma. A fim de se obter os mapas interpolados do teor de argila e da Ds, conforme mostra a Figura 1, os atributos foram interpolados individualmente, utilizando o complemento Smart-Map (PEREIRA et al., 2022). A rotina de análise pressupõe o ajuste do semivariograma ao conjunto de dados, sendo a escolha do modelo baseada em resultados de validação cruzada, priorizando o menor valor de resíduo junto ao maior coeficiente de determinação ( $R^2$ ). Utilizando-se as superfícies de argila e Ds, determinaram-se regiões por meio de análise de agrupamento não supervisionado com modelo nebuloso tomando o índice de performance fuzzy (FPI) e de entropia de classificação normalizada (NCE) para a definição do número de classes. A partir da delimitação das regiões foram atribuídos os valores médios da Ds em cada uma das regiões para a simulação da alteração da Ds.

**RESULTADOS E DISCUSSÃO:** Os resultados da análise descritiva, Tabela 1, demonstraram que a participação da fração argila oscilou entre 169 e 407 g kg<sup>-1</sup>, apresentando uma ampla faixa de composição granulométrica. A variabilidade no teor de argila e silte, expressas pelo coeficiente de variação (CV), estiveram acima de 20%, valor alto de acordo com (PIMENTEL-GOMES, 2009). Conforme se observa na Figura 1 a área de estudo apresentou um gradiente de granulometria do solo, com maior teor de argila na região norte.

Para os valores de Ds calculados houve baixa dispersão, oscilando entre 1,32 e 1,44 Mg m<sup>-3</sup>. Os maiores valores de Ds estiveram na região sul, ou seja na porção com maior participação da fração areia.

Os modelos dos semivariogramas para os atributos argila e Ds foram lineares. O efeito pepita apresentou valor de semivariância nulo para os modelos ajustados. Obteve-se um valor de alcance de 260,61 m para argila e 390,12 m para Ds. Ambos atributos apresentaram coeficiente de determinação de 0,98 na validação cruzada.

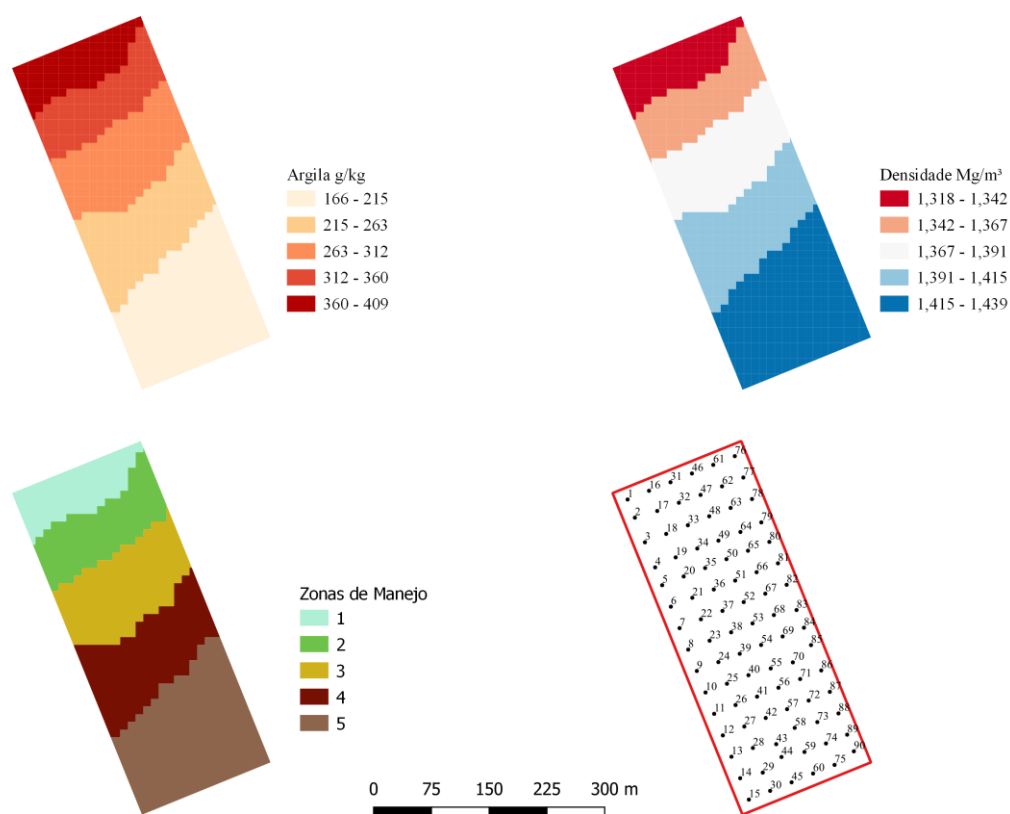
Na Figura 1, também são apresentadas as delimitações das regiões. As regiões 1, 2, 3, 4 e 5 apresentam áreas de 0,93; 1,26; 1,66; 1,70 e 2,55 ha respectivamente.

**Tabela 1.** Estatística descritiva da caracterização física do solo na camada de 0 a 0.4 m. **Descriptive statistics of the physical characterization of the soil in the 0 to 0.4 m layer.**

Momentos estatísticos	Argila	Silte	Areia	Ds
	g kg <sup>-1</sup>			Mg m <sup>-3</sup>
Média	263	20	717	1,39
Mediana	251	20	726	1,40
Mínimo	169	12	572	1,32
Máximo	407	44	812	1,44
Amplitude	238	33	240	0,12
Q.Inferior	201	17	669	1,37
Q.Superior	312	23	778	1,42

Desvio Padrão	68	5	69	0,03
Assimetria	0,45	1,32	-0,47	-0,45
Curtose	-0,88	4,95	-0,87	-0,88
CV (%)*	26,04	24,51	9,54	2,46
Número	90	90	90	90
Prob. <W*	0,000394	0,00005703	0,0002741	0,000394

\*Probabilidade de erro ao afirmar que a distribuição não é normal, valores maiores indicam distribuição normal segundo o teste de Shapiro-Wilk; Ds – densidade do solo.



**Figura 1.** Mapas de argila, densidade do solo, região de manejo e pontos amostrais. **Clay maps, soil density, management region and sampling points.**

Nas Tabelas 2 e 3, são apresentadas as características dimensionais dos tratores e semeadoras. O trator da classe II apresentou o menor valor de carga sobre o pneu, sendo de 1045 kg em cada pneu dianteiro e 1568 kg em cada pneu traseiro. O trator da classe IV, apresentou os maiores valores de carga sobre o pneu, tanto dianteiro como traseiro. O trator da classe V, apresentou valores de 1868 kg no pneu dianteiro e 2802 kg no pneu traseiro, vale ressaltar que para este caso foi considerado o uso de rodado duplo nos rodados dianteiros e traseiros.

Ao avaliar a relação peso-potência, Tabela 2, nota-se que o trator da classe IV apresentou o maior valor de 73,45 kg kW<sup>-1</sup>. Conforme Francetto et al. (2011), tratores da classe II e IV, apresentam valores médios da relação peso-potência de 68,18 e 60,97 kg kW<sup>-1</sup>, respectivamente. A relação de peso-potência dos tratores na classe II e IV utilizados na simulação foram 4,98 e 20,46% superiores respectivamente, para classe II e IV.

**Tabela 2.** Características e parâmetros de entrada dos tratores das classes II, IV e V utilizados para simular a tensão de contato e deformação do solo com o modelo *soilphysics*. **Input parameters of class II, IV and V tractors used to simulate soil contact stress and deformation with the *soilphysics* model.**

Classe	Potência do motor (kW)	Peso/Potência (kg/kW)	Eixo	Modelo do Pneu	Pressão do pneu (kPa)	Largura do pneu (m)	Diâmetro do pneu (m)	Área de contato do pneu (m <sup>2</sup> )	Carga no pneu (kg)
II	73	71,58	Dianteiro	11,2-28 R1	179	0,28	1,21	0,14	1045,00
			Traseiro	13,6-38 R1	193	0,35	1,57	0,22	1568,00
IV	177	73,45	Dianteiro	600/65 R28 A8 R1W	159	0,60	1,49	0,39	2600,00
			Traseiro	710/70R38 A8 R1W	241	0,71	1,96	0,61	3900,00
V	320	58,37	Dianteiro	480/70R34 R1W DUAL	241	0,48	1,54	0,31	1868,00
			Traseiro	800/70R38 R1W DUAL	241	0,80	2,09	0,74	2802,00

A classe II obteve as menores larguras efetiva de trabalho de 3,00 e 2,50 m, para os mecanismos sulcaros do tipo disco duplo e haste sulcadora respectivamente. A classe IV apresentou como largura efetiva de trabalho 8,00 e 6,50 m, para mecanismos sulcadores do tipo disco duplo e haste sulcadora. A classe V obteve as maiores larguras efetivas de trabalho com 15,00 e 11,00 m, para os mecanismos sulcadores do tipo disco duplo e haste sulcadora respectivamente. Essa diferença se dá pelo fato da potência demandada na barra de tração pelos diferentes tipos de mecanismo sulcador, sendo que o de haste sulcadora demanda maior potência e como consequência permine menor número de linhas e largura de trabalho, Tabela 3.

**Tabela 3.** Parâmetros das semeadoras com mecanismo sulcador de fertilizantes do tipo disco duplo e haste sulcadora. **Parameters of seeders with double disc fertilizer furrower mechanism and furrower rod.**

Classe	Nº de linhas	Distância entre linhas (m)	Mecanismo sulcador	Largura de trabalho (m)
II	6	0,5	Disco duplo	3,00
	5	0,5	Haste sulcadora	2,50
IV	16	0,5	Disco duplo	8,00
	13	0,5	Haste sulcadora	6,50
V	30	0,5	Disco duplo	15,00
	22	0,5	Haste sulcadora	11,00

Na Tabela 4, são apresentados o comprimento total das linhas de trabalho para cada uma das regiões A região 5, menos argilosa, apresentou maior comprimento das linhas de trabalho. A região 1, mais argilosa, apresentou menor comprimento das linhas de tráfego. Em contrapartida a região 5, menos argilosa, apresentou maior comprimento das linhas de tráfego.

**Tabela 4.** Comprimento das linhas de trabalho delimitado pelas regiões 1, 2, 3, 4 e 5 para as classes de tratores II, IV e V. **Length of working lines delimited by regions 1, 2, 3, 4 and 5 for tractor classes II, IV and V.**

Classe	Nº de linhas da semeadora	Largura de trabalho (m)	Soma do comprimento linhas passadas por pneu em cada região (m)				
			1	2	3	4	5


II	6	3,00	6164	8426	11061	11328	17032
	5	2,50	7399	10113	13271	13595	20394
IV	16	8,00	2309	3157	4155	4242	6301
	13	6,50	2839	3898	5098	5228	7782
V	30	15,00	1250	1664	2192	2262	3434
	22	11,00	1679	2303	3013	3091	4677

Na Tabela 5, são apresentados os percentuais de pisoteio para os pneus dianteiros e traseiros em cada região. Os valores oscilaram entre 17,54 e 46,81% demonstrando como o tipo de equipamento e a variabilidade espacial podem levar a intensidades bastante distintas de tráfego. O mecanismo sulcador o tipo haste sulcadora foi o que apresentou maior porcentagem da área pisoteada pelos pneus dianteiros e traseiros, nas classes II, IV e V.

Tabela 5. Percentual de pisoteio para os pneus dianteiros e traseiros para as regiões 1, 2, 3, 4, e 5 para as classes de tratores II, IV e V. **Trample percentage for front and rear tires for regions 1, 2, 3, 4, and 5 for tractor classes II, IV e V.**

Classe	Mecanismo sulcador	Área pisoteada pelo pneu dianteiro em cada região (%)					Área pisoteada pelo pneu traseiro em cada região (%)				
		1	2	3	4	5	1	2	3	4	5
II	Disco duplo	37,12	37,45	37,31	37,31	37,40	46,40	46,81	46,64	46,64	46,75
	Haste sulcadora	44,55	44,95	44,77	44,78	44,79	27,85	28,09	27,98	27,99	27,99
IV	Disco duplo	29,79	30,07	30,04	29,94	29,65	17,63	17,79	17,77	17,72	17,54
	Haste sulcadora	36,64	37,12	36,85	36,91	36,62	21,68	21,96	21,80	21,84	21,67
V	Disco duplo	25,81	25,35	25,35	25,55	25,86	21,51	21,12	21,13	21,29	21,55
	Haste sulcadora	34,65	35,10	34,85	34,91	35,22	28,88	29,25	29,04	29,09	29,35

Na Figura 2, é apresentado o estresse máximo aplicado pelo pneus dianteiros e traseiros das classes II, IV e V. Para os pneus dianteiros o estresse máximo foi de 244, 232 e 320 kPa, para as classes II, IV e V, respectivamente. Para os pneus traseiros o estresse máximo foi de 264, 334 e 327 kPa, para as classes II, IV e V, respectivamente. Segundo Severiano et al. (2013), a pressão de preconsolidação máxima para latossolos no potencial mátrico de 100 hPa, com teores de argila variando entre 209 e 263 g kg<sup>-1</sup> é de 166 kPa. Como podemos observar tanto para os pneus dianteiros como para os pneus traseiros nas classes II, IV e V o estresse máximo induzido ao solo foi superior a este limite crítico. A classe IV apresenta a maior discrepância entre a pressão aplicada pelo pneus dianteiros e traseiros, uma diferença de 43,97%.



**Figura 2.** Estresse máximo aplicado ao solo pelos pneus dianteiros e traseiros. **Maximum stress applied to the soil by the front and rear tires.**

Nas Tabelas 6 e 7, são apresentadas a Ds após a passagem simulada dos tratores. Para a classe II os pneus dianteiros provocariam incremento na Ds do solo, até a profundidade de 0,05 m, entretanto para a região 1 que possui média de 386 g kg<sup>-1</sup> de argila a alteração na Ds ocorreria até a profundidade de 0,10 m. Para este mesmo modelo de trator os pneus traseiros provocariam incremento na Ds do solo até a profundidade de 0,10 m em todas as regiões.

Na classe V os pneus dianteiros provocariam incremento na Ds do solo nas camadas entre 0,05 a 0,15 m de profundidade. Nas regiões 1 e 2 que apresentam teores médios de argila de 386 e 334 g kg<sup>-1</sup>, respectivamente, é possível observar que haveria incremento na Ds do solo até a profundidade de 0,20 m. Para o pneu traseiro, haveria incremento na Ds do solo entre as camadas de 0,05 a 0,20 m. Para os pneus dianteiros o mesmo acontece e nas regiões 1 e 2, mais argilosas, houve incremento na Ds do solo até a profundidade de 0,30 m.

Alterações na Ds do solo na camada de 0,05 a 0,15 m, também foram observadas por Collares et al. (2008), em um Latossolo Vermelho argiloso, corroborando os resultados obtidos por meio da simulação. Segundo Voorhees; Senst; Nelson (1978) e Voorhees; Nelson; Randall (1986), máquinas agrícolas com carga por eixo superior a 4,5 Mg proporcionam aumento da Ds do solo em profundidades até maiores que 0,30 m. A compactação abaixo da profundidade de 0,30 m é função da carga total por eixo e a compactação em superfície é função da pressão de inflação dos pneus (SALIRE; HAMMEL; HARDCASTLE, 1994).

Para a classe IV, haveria incremento na Ds do solo nas camadas entre 0,05 e 0,15 para os pneus dianteiros, e entre as camadas de 0,05 a 0,20 m para os pneus traseiros. Na região 1 para o pneu traseiro haveria incremento entre as profundidades de 0,05 a 0,30 m.

Nas regiões 3, 4 e 5 com teores médios de argila de 280, 236 e 188 g kg<sup>-1</sup>, para a classe II e pneus dianteiros alterações ocorreriam até a profundidade de 0,05 m. No caso dos pneus traseiros alterações ocorreriam até 0,10 m de profundidade e os valores da Ds foram superiores a 1,40 Mg m<sup>-3</sup>. Para as classes IV e V, nas regiões 3, 4 e 5, para os pneus dianteiros entre as profundidades de 0,05 a 0,15 m, e para os pneus traseiros entre as profundidades de 0,05 e 0,20 m, os valores da Ds do solo foram superiores a 1,40 Mg m<sup>-3</sup>. Silva et al. (2009) considerou como Ds crítica dos Latossolos o valor de 1,40 Mg m<sup>-3</sup> pelo método do intervalo hídrico ótimo.

Tabela 6. Densidade do solo e variação na densidade do solo após passada do pneu dianteiro. Soil density and variation in soil density after passing the front tire.

Classe do Trator	Prof. (m)	Ds após a passada do pneu em cada região (Mg m <sup>-3</sup> )					Incremento na Ds em cada região (%)				
		1	2	3	4	5	1	2	3	4	5
II	0,05	1,37	1,40	1,41	1,43	1,46	2,95	2,60	2,42	2,28	2,13
	0,10	1,34	1,36	1,38	1,40	1,43	0,57	0,27	0,12	0,00	0,00
	0,15	1,33	1,36	1,38	1,40	1,43	0,00	0,00	0,00	0,00	0,00
	0,20	1,33	1,36	1,38	1,40	1,43	0,00	0,00	0,00	0,00	0,00
	0,30	1,33	1,36	1,38	1,40	1,43	0,00	0,00	0,00	0,00	0,00
	0,40	1,33	1,36	1,38	1,40	1,43	0,00	0,00	0,00	0,00	0,00
IV	0,05	1,38	1,40	1,42	1,44	1,47	3,66	3,30	3,11	2,95	2,79
	0,10	1,36	1,39	1,40	1,42	1,45	2,26	1,93	1,75	1,61	1,48
	0,15	1,34	1,37	1,39	1,41	1,43	0,95	0,65	0,49	0,37	0,26
	0,20	1,33	1,36	1,38	1,40	1,43	0,00	0,00	0,00	0,00	0,00
	0,30	1,33	1,36	1,38	1,40	1,43	0,00	0,00	0,00	0,00	0,00
	0,40	1,33	1,36	1,38	1,40	1,43	0,00	0,00	0,00	0,00	0,00
V	0,05	1,40	1,43	1,44	1,46	1,49	5,20	4,81	4,59	4,41	4,22
	0,10	1,38	1,40	1,42	1,44	1,47	3,57	3,21	3,01	2,86	2,71
	0,15	1,36	1,38	1,40	1,42	1,45	2,05	1,72	1,54	1,41	1,29
	0,20	1,34	1,37	1,38	1,40	1,43	0,68	0,38	0,22	0,11	0,01
	0,30	1,33	1,36	1,38	1,40	1,43	0,00	0,00	0,00	0,00	0,00
	0,40	1,33	1,36	1,38	1,40	1,43	0,00	0,00	0,00	0,00	0,00

Tabela 7. Densidade do solo e variação na densidade do solo após passada do pneu traseiro. Soil density and variation in soil density after passing the rear tire.

Classe do Trator	Prof. (m)	Ds após a passada do pneu em cada região (Mg m <sup>-3</sup> )					Incremento na Ds em cada região (%)				
		1	2	3	4	5	1	2	3	4	5
II	0,05	1,38	1,41	1,43	1,45	1,47	3,94	3,57	3,38	3,21	3,05
	0,10	1,36	1,38	1,40	1,42	1,45	1,96	1,63	1,46	1,33	1,20
	0,15	1,33	1,36	1,38	1,40	1,43	0,22	0,00	0,00	0,00	0,00
	0,20	1,33	1,36	1,38	1,40	1,43	0,00	0,00	0,00	0,00	0,00
	0,30	1,33	1,36	1,38	1,40	1,43	0,00	0,00	0,00	0,00	0,00



	0,40	1,33	1,36	1,38	1,40	1,43	0,00	0,00	0,00	0,00	0,00
	0,05	1,41	1,43	1,45	1,47	1,50	5,79	5,38	5,16	4,98	4,78
	0,10	1,39	1,42	1,43	1,45	1,48	4,57	4,18	3,98	3,81	3,64
	0,15	1,38	1,40	1,42	1,44	1,47	3,44	3,08	2,89	2,74	2,58
IV	0,20	1,36	1,39	1,41	1,42	1,45	2,38	2,04	1,87	1,73	1,59
	0,30	1,34	1,36	1,38	1,40	1,43	0,46	0,15	0,01	0,00	0,00
	0,40	1,33	1,36	1,38	1,40	1,43	0,00	0,00	0,00	0,00	0,00
	0,05	1,41	1,43	1,45	1,47	1,50	5,81	5,40	5,18	5,00	4,80
	0,10	1,39	1,42	1,44	1,45	1,48	4,68	4,29	4,08	3,91	3,73
	0,15	1,38	1,40	1,42	1,44	1,47	3,60	3,24	3,04	2,89	2,73
V	0,20	1,36	1,39	1,41	1,43	1,46	2,62	2,28	2,09	1,96	1,82
	0,30	1,34	1,37	1,38	1,40	1,43	0,80	0,49	0,33	0,21	0,11
	0,40	1,33	1,36	1,38	1,40	1,43	0,00	0,00	0,00	0,00	0,00

**CONCLUSÃO:** Os modelos preditivos da compactação do solo mostraram que a operação de semeadura utilizando trator da classe V provocou alteração na densidade do solo até a profundidade de 0,30 m. O trator da classe II, apresentou maior área sob influência dos rodados dianteiros e traseiros, entretanto, apresentou danos na estrutura do solo na camada de 0,05 m para os pneus dianteiros e nas camadas de 0,05 e 0,10 m para os pneus traseiros. A intensidade e profundidade de alteração da estrutura do solo oscilaram espacialmente demonstrando que o efeito da aplicação de uma mesma carga tende a causar efeitos distintos ao longo das áreas que apresentam variabilidade na composição granulométrica do solo. O estresse máximo gerado ao solo e a densidade do solo após a passagem dos pneus ficaram acima do limite crítico na maior parte das vezes, representando risco potencial de compactação do solo.

## REFERÊNCIAS

ALAPA. **Manual de Normas Técnicas - 2019/2020/2021**. [s.l: s.n.]

ASAE, A. S. of Ag. E. The American Society of Agricultural Engineers. In: **ASAE Standards**. [s.l: s.n.]p. 343–349.

BENGOUGH, A. G. et al. Root responses to soil physical conditions; growth dynamics from field to cell. **Journal of Experimental Botany**, v. 57, n. 2 SPEC. ISS., p. 437–447, 2006.

BENITES, V. M. et al. Pedotransfer functions for estimating soil bulk density from existing soil survey reports in Brazil. **Geoderma**, v. 139, n. 1–2, p. 90–97, 2007.

BOSCHI, R. S. et al. How accurate are pedotransfer functions for bulk density for brazilian soils? **Scientia Agricola**, v. 75, n. 1, p. 70–78, 2018.

CAMARGO, O. A. de et al. **Métodos de Análise Química, Mineralógica e Física de Solos do Instituto Agronômico de Campinas**. [s.l: s.n.]v. 106

COLLARES, G. L. et al. Compactação de um latossolo induzida pelo tráfego de máquinas e sua relação com o crescimento e produtividade de feijão e trigo. **Revista Brasileira de Ciência do Solo**, v. 32, n. 3, p. 933–942, 2008.

DIAS, C. **Estudo revela que 30% dos solos do mundo estão degradados**. Disponível em: <<https://www.embrapa.br/busca-de-noticias/-/noticia/14343883/estudo-revela-que-30-dos-solos-do-mundo-estao-degradados>>. Acesso em: 12 abr. 2022.

FRANCETTO, T. R. et al. Avaliação da relação peso/potência de tratores agrícolas com tração dianteira auxiliar (TDA) conforme as suas respectivas classes de potência. In: XL Congresso brasileiro de engenharia agrícola - CONBEA, July, **Anais...**2011.

FROHLICH, O. K. **Druckverteilungim Baugrunde (Pressure Distribution in Soil Foundation)**. Wien: Springer, 1934.

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.

HORN, R. et al. Soil compaction processes and their effects on the structure of arable soils and the environment. **Soil and Tillage Research**, v. 35, n. 1–2, p. 23–36, 1995.

KELLER, T. A Model for the prediction of the contact area and the distribution of vertical stress below agricultural tyres from readily available tyre parameters. **Biosystems Engineering**, v. 92, n. 1, p. 85–96, 2005.

KELLER, T. et al. SoilFlex: A model for prediction of soil stresses and soil compaction due to agricultural field traffic including a synthesis of analytical approaches. **Soil and Tillage Research**, v. 93, n. 2, p. 391–411, 2007.

KELLER, T. et al. Transmission of vertical soil stress under agricultural tyres: Comparing measurements with simulations. **Soil and Tillage Research**, v. 140, p. 106–117, 2014.

KELLER, T. et al. Historical increase in agricultural machinery weights enhanced soil stress levels and adversely affected soil functioning. **Soil and Tillage Research**, v. 194, n. May, p. 104293, 2019. Disponível em: <<https://doi.org/10.1016/j.still.2019.104293>>.

LIMA, R. P. et al. Impact of initial bulk density and matric suction on compressive properties of two Oxisols under no-till. **Soil and Tillage Research**, v. 175, n. September 2017, p. 168–177, 2018. Disponível em: <<https://doi.org/10.1016/j.still.2017.09.003>>.

LIMA, R. P.; DA SILVA, A. R.; DA SILVA, Á. P. soilphysics: An R package for simulation of soil compaction induced by agricultural field traffic. **Soil and Tillage Research**, v. 206, n. March 2020, 2021.

MCPHEE, J. E. et al. Managing soil compaction – A choice of low-mass autonomous vehicles or controlled traffic? **Biosystems Engineering**, v. 195, p. 227–241, 2020. Disponível em: <<https://doi.org/10.1016/j.biosystemseng.2020.05.006>>.

O’SULLIVAN, M. F.; ROBERTSON, E. A. G. Critical state parameters from intact samples of two agricultural topsoils. **Soil and Tillage Research**, v. 39, n. 3–4, p. 161–173, 1996.

PEREIRA, G. W. et al. Soil mapping for precision agriculture using support vector machines combined with inverse distance weighting. **Precision Agriculture**, n. 0123456789, 2022. Disponível em: <<https://doi.org/10.1007/s11119-022-09880-9>>.

PIMENTEL-GOMES, F. **Curso de Estatística Experimental**. 15. ed. Piracicaba: Fealq, 2009.

QGIS.ORG. **QGIS Geographic Information System**. Disponível em: <<http://www.qgis.org>>.

QUEVEDO, G. Anuário de Tratores Agrícolas 2021/22. **Cultivar Máquinas**, p. 108, ago. 2021.

R CORE TEAM. **R: A language and environment for statistical computing**. Disponível em: <[www.R-project.org/](http://www.R-project.org/)>.

SALIRE, E. V.; HAMMEL, J. E.; HARDCASTLE, J. H. Compression of intact subsoils under short-duration loading. **Soil and Tillage Research**, v. 31, n. 2–3, p. 235–248, 1994.

SENAR. **Operação de tratores agrícolas**. [s.l: s.n.]

SEVERIANO, E. D. C. et al. Preconsolidation pressure, soil water retention characteristics, and texture of Latosols in the Brazilian Cerrado. **Soil Research**, v. 51, n. 3, p. 193–202, 2013.

SHAHEB, M. R.; VENKATESH, R.; SHEARER, S. A. A Review on the Effect of Soil Compaction and its Management for Sustainable Crop Production. **Journal of Biosystems Engineering**, v. 46, n. 4, p. 417–439, 2021. Disponível em: <<https://doi.org/10.1007/s42853-021-00117-7>>.

SILVA, V. R. et al. Soil water dynamics related to the degree of compaction of two brazilian oxisols under no-tillage. **Revista Brasileira de Ciencia do Solo**, v. 33, n. 5, p. 1097–1104, 2009.

SÖHNE, W. Druckverteilung im Boden und Bodenverformung unter Schlepperreifen. **Grundlagen der Landtechnik - Konstrukteurhefte**, n. 5, p. 49–63, 1953. Disponível em: <<http://440ejournals.uni-hohenheim.de/index.php/Konstrukteur/article/view/1721>>.

VOORHEES, W. B.; NELSON, W. W.; RANDALL, G. W. Extent and Persistence of Subsoil Compaction Caused by Heavy Axle Loads. **Soil Science Society of America Journal**, v. 50, n. 2, p. 428–433, 1986.

VOORHEES, W. B.; SENST, C. G.; NELSON, W. W. Compaction and Soil Structure Modification by Wheel Traffic in the Northern Corn Belt. **Soil Science Society of America Journal**, v. 42, n. 2, p. 344–349, 1978.

# MAPAS DE NDVI PARA DEFINIÇÃO DE UNIDADES DE MANEJO DIFERENCIADAS PARA A VITIVINICULTURA

André Luis Vian<sup>1</sup>; JÚLIA FACCI FAÉ<sup>2</sup>; LUÍS FELIPE GERLACH<sup>3</sup>; ALEXANDRE ALAN CASSINELLI<sup>4</sup>; GABRIEL RIEDER MARSON<sup>4</sup>

<sup>1</sup>Engenheiro Agrônomo, Prof. Dr - Departamento de PLantas de Lavoura, Avenida Bento Gonçalves, 7712, CEP 91540-000, Porto Alegre, Rio Grande do Sul, Brasil.. andre.vian@ufrgs.br / (55) 9 9900-2542;

<sup>2</sup>Engenheira Agrônoma, Mestranda - PPG-Fitotecnia - UFRGS, Avenida Bento Gonçalves, 7712, CEP 91540-000, Porto Alegre, Rio Grande do Sul, Brasil.; <sup>3</sup>Engenheiro Agrônomo, Doutorando - PPG-Fitotecnia - UFRGS, Avenida Bento Gonçalves, 7712, CEP 91540-000, Porto Alegre, Rio Grande do Sul, Brasil.;

<sup>4</sup>Acadêmico do curso de agronomia, Bolsista - Faculdade de Agronomia - UFRGS, Avenida Bento Gonçalves, 7712, CEP 91540-000, Porto Alegre, Rio Grande do Sul, Brasil.

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Na vitivinicultura brasileira a utilização da Agricultura de Precisão (AP) é recente e ainda se faz necessário o conhecimento e adaptabilidade das ferramentas de AP na cultura. O objetivo do presente trabalho é utilizar o Índice de Vegetação por Diferença Normalizada (NDVI) para definição de zonas de manejo diferenciadas como uma forma de entendimento da gestão da variabilidade temporal do vinhedo. Para realização do estudo foram utilizadas duas quadras em um vinhedo comercial, das variedades de Merlot e Chardonnay, onde foi determinado três ambientes de produção baseados na média de sete mapas de NDVI ao longo de dois anos, em diferentes datas durante o ciclo da planta, por meio da plataforma Auravant. Os resultados obtidos até o presente momento indicam que são necessárias adequações para a cultura da videira.

**PALAVRAS-CHAVE:** *Vitis vinifera*; imagens de satélite; variabilidade espacial

## NDVI MAPS FOR THE DEFINITION OF DIFFERENTIATED MANAGEMENT UNITS FOR WINE VINES

**ABSTRACT:** In Brazilian viticulture, the use of Precision Agriculture (PA) is recent and knowledge and adaptability of PA tools in culture is still necessary. The objective of the present work is to use the Normalized Difference Vegetation Index (NDVI) to define differentiated management zones as a way of understanding the management of the temporal variability of the vineyard. To carry out the study, two blocks were used in a commercial vineyard, of the Merlot and Chardonnay varieties, where three production environments were determined based on the average of seven NDVI maps over two years, at different dates during the plant cycle, for through the Auravant platform. The results obtained so far indicate that adjustments are necessary for the vine culture.

**KEYWORDS:** *Vitis vinifera*; satellite images; spatial variability

**INTRODUÇÃO:** No setor vitivinícola, a utilização de ferramentas tecnológicas de Agricultura de Precisão (AP) é recente (BRAMLEY; HAMILTON, 2004; ARNÓ et al., 2009), e mesmo com a grande aptidão frutícola do Brasil, as ferramentas tecnológicas ainda não são amplamente utilizadas, ganhando pequenos espaços em culturas como citros, videira, macieira, dentre outras culturas. Ainda existem diversos impasses para se tenha uma maior adoção, como o conhecimento das ferramentas disponíveis no mercado, sua empregabilidade no campo e adaptabilidade às condições impostas pelas culturas frutíferas, como é o caso da viticultura.

O auxílio que as ferramentas de AP podem gerar como a mecanização, análise de solos, sensoriamento remoto, o uso de Índice de Vegetação por Diferença Normalizada (NDVI) para definição de zonas de manejo diferenciadas, surgem como uma forma de entendimento da gestão da variabilidade temporal de solo e de planta, buscando a melhoria do rendimento produtivo, de qualidade e econômico.

O NDVI é um dos índices mais utilizados na agricultura atualmente, pois relaciona-se com a concentração de clorofila e com a biomassa da planta. Os sensores de vegetação, como sensores proximais, imagens de satélites, imagens proximais, visam obter dados de reflectância em tempo real da planta que podem ser correlacionados com parâmetros de estado nutricional, de início de rebrote, ataque de pragas, doenças, dentre outros fatores de estresses bióticos e abióticos (AMMONIACI et al., 2021).

O objetivo deste trabalho foi propor um estudo para auxiliar na definição de unidades de manejo diferenciadas, a fim de encontrar condições avançadas do manejo dos vinhedos, uma vez que possibilitam o entendimento da micro variabilidade espacial do solo e de plantas, que possam auxiliar na redução dos custos de produção e aumento da competitividade do setor vitivinícola nacional.

**MATERIAIS E MÉTODOS:** O trabalho foi desenvolvido em duas quadras de um vinhedo comercial pertencente à empresa Casa Ângelo Fantin, localizado no município de Monte Belo do Sul (RS). O experimento foi realizado com as variedades: Chardonnay e Merlot, cultivadas sob sistema de condução espaldeira e com 8 e 12 anos, respectivamente (Figura 1).




FIGURA 1. Localização das quadras de Merlot e Chardonnay utilizadas no experimento. **Location of Merlot and Chardonnay blocks used in the experiment.**

Para definir os ambientes de produção usando unidades de manejo diferenciada em três ambientes de produção, utilizou-se a média de sete mapas de Índice de vegetação por diferença normalizada (NDVI) das safras 2020 e 2021, em diferentes períodos do ano que conferem diferentes estádios de desenvolvimento da cultura (20/06/2020, 21/09/2020, 22/11/2020, 15/12/20, 31/08/21, 25/10/21, 04/11/21). As informações de NDVI foram obtidas via imagens de satélites com 3m x 3m, sendo essas imagens obtidas por satélites da Constelação Planet e a plataforma utilizada para a análise dos dados, processamento das imagens e construção das unidades de manejo foi a plataforma Auravant. O algoritmo utilizado pela plataforma foi mensurado o NDVI médio de cada pixel para obter a variabilidade espacial do mapa e assim realizar posteriormente a interpolação para determinação das unidades de manejo.


As unidades de manejo propostas foram classificadas em baixo, médio e alto potencial produtivo de acordo com o valor médio de NDVI para classificação. Considerando a variabilidade espacial existente de cada área, definiu-se para cada área diferentes classes para cada área, sendo os valores apresentados na tabela abaixo (Tabela 1).

**TABELA 1.** Valores médios de NDVI utilizados para a classificação dos ambientes de produção nas áreas. **Average values of NDVI used for the classification of production environments in the areas.**


Ambiente de produção	Merlot	Chardonnay
Alto potencial (AA)	0,73 a 0,81	0,70 a 0,79

Médio potencial (AM)	0,64 a 0,73	0,60 a 0,70
Baixo potencial (AB)	0,55 a 0,64	0,51 a 0,60

**RESULTADOS E DISCUSSÃO:** Nas Figuras 2 (quadra com a cultivar Merlot) e 3 (quadra com a cultivar Chardonnay), são apresentados os sete mapas de Índice de Vegetação por Diferença Normalizada (NDVI) que foram utilizados para a construção das unidades de manejo diferenciado de produção (UMD), que foram utilizados para a interpolação e construção das médias de definição dos ambientes de potenciais produtivos distintos.



**FIGURA 2.** Os sete mapas da esquerda são os diferentes mapas utilizados para a construção das unidades de manejo diferenciada da quadra Merlot (direita). **The seven maps on the left are the different maps used for the construction of the differentiated management units of the Merlot block (right).**



**FIGURA 3.** Os sete mapas da esquerda são os diferentes mapas utilizados para a construção das unidades de manejo diferenciada da quadra Chardonnay (direita). **The seven maps on the left are the different maps used for the construction of the differentiated management units of the Chardonnay block (right).**

Na safra 2022 foram realizadas as análises de produção e de qualidade do mosto da uva nos cinco pontos amostrais, os quais são compostos por cinco plantas e distribuídos nos três ambientes de produção em cada quadra do experimento, totalizando 15 pontos amostrais por ambiente de potencial produtivo e 30 pontos no total do experimento.

Pode-se observar que na quadra Merlot (Tabela 2) houveram diferenças significativas na produção entre os ambientes de baixo e médio potencial produtivo, porém não houve diferença nas médias entre o ambiente de alto potencial em relação ao de baixo e médio potencial produtivo, bem como também não houveram diferenças significativas entre esses dois ambientes, indicando que poderiam ser utilizadas somente duas zonas de manejo ao invés de três zonas, como apresentado por Martinez-Casasnovas *et al.* (2012), em um estudo para analisar o potencial dos mapas NDVI na construção de zonas de manejo para colheita seletiva.

Verificou-se nas análises qualitativas do mosto da uva, nenhuma diferença significativa quanto Brix° e pH do mosto nos três ambientes de produção, entretanto, a acidez total foi maior no ambiente de baixo potencial produtivo e menor nos ambientes de médio e alto potencial, o que pode ser justificado pela menor produção nesses dois ambientes e maior grau Brix°, que consequentemente propicia uma melhor qualidade da uva, em virtude da relação Brix°/AT do mosto que confere equilíbrio gustativo ao vinho (GUERRA, 2002).

**TABELA 2.** Resultado das análises de variância e do teste de comparação de médias para avaliar a produção (kg/ha), média de cachos/planta, e variáveis de qualidade de mosto, sendo Brix°, Acidez total (AT) nos três ambientes de produção da quadra Merlot. **Result of the analysis of variance and of the test of comparison of averages to evaluate the production (kg/ha), average of bunches/plant, and variables of quality of must, being Brix°, Total Acidity (AT) in the three production environments of the block Merlot.**

Merlot					
Unidades de manejo	Produção (Kg/ha)	cacho/planta	Brix°	AT	pH
AA	9353.3 ab	25,4	22,0	7.5 b	3,6
AM	8766.7 b	27,3	21,9	7.7 b	3,6
AB	10922.7 a	25,4	21,2	8.4 a	3,5
Análise	*	ns	ns	*	ns

\* Médias seguidas de mesmas letras minúsculas nas colunas pelo teste de Tukey ( $p>0,05$ ). ns – não significativo.

Na quadra Chardonnay (Tabela 3) pode-se observar que houve diferenças significativas na produção entre o ambiente de baixo potencial produtivo, o qual obteve uma produção maior em relação ao de médio e alto potencial produtivo, que novamente não apresentaram diferenças significativas em relação a produção, Brix° e pH. Observou-se nas análises qualitativas do mosto da uva, diferença significativa quanto a acidez total, a qual foi maior nos ambientes de baixo e médio potencial em relação ao ambiente de alto potencial que apresentou menor AT, podendo ser justificado em função do seu maior grau Brix° (açúcar), que conseqüentemente diminui a AT (GUERRA, 2022).

**TABELA 3.** Resultado das análises de variância e do teste de comparação de médias para avaliar a produção (kg/ha), média de cachos/planta, e variáveis de qualidade de mosto, sendo Brix°, Acidez total (AT) nos três ambientes de produção da quadra Chardonnay. **Result of the analysis of variance and of the test of comparison of averages to evaluate the production (kg/ha), average of bunches/plant, and variables of quality of must, being Brix°, Total Acidity (AT) in the three production environments of the block Chardonnay.**

Chardonnay					
Unidades de manejo	Produção (Kg/ha)	cacho/planta	Brix°	AT	pH
AA	9033.3 b	33,2 a	22,0	6.8 b	3,6
AM	9073.3 b	35,0 a	21,4	7.4 a	3,5
AB	9793.3 a	18,9 b	21,8	7.4 a	3,5
Análise	*	*	ns	*	ns

\* Médias seguidas de mesmas letras minúsculas nas colunas pelo teste de Tukey ( $p>0,05$ ). ns – não significativo.

**CONCLUSÃO:** Os dados preliminares demonstram que os ambientes de potencial produtivo determinados através da média de mapas de NDVI pela plataforma Auravant não apresentaram relação com a produção, necessitando de maiores estudos para adequação à cultura da videira.

Ainda é importante salientar que apesar dos resultados desse experimento não se adequarem com o esperado, podem indicar novos caminhos para estudos futuros na AP para a vitivinicultura, de forma que, ainda são necessários ajustes das ferramentas de AP para o setor vitivinícola.

#### **AGRADECIMENTOS:**

Os autores agradecem a Universidade Federal do Rio Grande do Sul (UFRGS), ao Programa de Pós-Graduação em Fitotecnia (PPGFITO), ao Grupo de Estudos em Agricultura Digital (GEAD), e a Casa Ângelo Fantin pela disponibilidade em utilizar suas instalações e equipamentos e a Vinícola Adega da Serra pela disponibilidade de uso de seu Laboratório de análises químicas.

#### **REFERÊNCIAS**

AMMONIACI, M. *et al.* State of the Art of Monitoring Technologies and Data Processing for Precision Viticulture. **Agriculture**, Suíça, v. 11, n. 3, p. 201, 2021. Disponível em: <https://www.mdpi.com/2077-0472/11/3/201>. Acesso em: 26 abr. 2022.

ARNÓ, J. *et al.* Review. Precision viticulture. Research topics, challenges and opportunities insite-specific vineyard management. **Spanish Journal of Agricultural Research**, Espanha, v.7, n. 4, p. 779, 2009. Disponível em: <http://revistas.inia.es/index.php/sjar/article/view/1092>. Acesso em: 21 abr. 2022.

BRAMLEY, R.G.V; HAMILTON, R.P. (2004) Understanding variability in winegrape production systems. 1. Within vineyard variation in yield over several vintages. **Australian Journal of Grape and Wine Research**, Australia, v. 10, p. 32–45, 2004. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1111/j.1755-0238.2004.tb00006.x>. Acesso em: 20 abr. 2022.

GUERRA, C. C. Maturação da uva e condução da vinificação para a elaboração de vinhos finos. IN: **Simpósio Mineiro de Viticultura e Enologia**, Minas Gerais, p. 179-192. 2002. Disponível em: <http://ainfo.cnptia.embrapa.br/digital/bitstream/item/148891/1/Guerra-SMVE -p179-192.pdf>. Acesso em: 26 abr. 2022.

MARTINEZ-CASASNOVAS, J. A. *et al.* Analysis of vineyard differential management zones and relation to vine development, grape maturity and quality. **Spanish Journal of Agricultural Research**, [s. l.], v. 10, n. 2, p. 326–337, 2012. Disponível em: <https://revistas.inia.es/index.php/sjar/article/view/1998>. Acesso em: 01 mai. 2022.



# ESPECTROSCOPIA DE INFRAVERMELHO PRÓXIMO (NIR) PARA ESTIMATIVA DO TEOR DE NITROGÊNIO EM TECIDO VEGETAL DE MILHO

André Luis Vian<sup>1</sup>; ELISA MARIA BERFT<sup>4</sup>; VICTOR FAGUNDES ABIANNA<sup>4</sup>; DIEGO LIMA LUCCHESI<sup>2</sup>; GABRIELA NAIBO<sup>3</sup>

<sup>1</sup>Engenheiro Agrônomo, Prof. Dr. - Departamento de Plantas de Lavoura, Avenida Bento Gonçalves, 7712, CEP 91540-000, Porto Alegre, Rio Grande do Sul, Brasil.. andre.vian@ufrgs.br / (55) 9 9900-2542;

<sup>2</sup>Engenheiro Agrônomo, Menstrando - PPG-Fitotecnia - UFRGS, Avenida Bento Gonçalves, 7712, CEP 91540-000, Porto Alegre, Rio Grande do Sul, Brasil.; <sup>3</sup>Engenheira Florestal, Doutoranda - PPG - Ciência do Solo UFRGS, Avenida Bento Gonçalves, 7712, CEP 91540-000, Porto Alegre, Rio Grande do Sul, Brasil.;

<sup>4</sup>Acadêmico de agronomia, Bolsista - Faculdade de Agronomia - UFRGS, Avenida Bento Gonçalves, 7712, CEP 91540-000, Porto Alegre, Rio Grande do Sul, Brasil.

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Os métodos tradicionalmente utilizados para análise das concentrações de nutrientes em tecido vegetal e grãos, são caros, ineficientes e apresentam riscos devido ao uso de reagentes químicos. A espectroscopia do visível e do infravermelho próximo – VIS/NIRS (Near Infrared Spectroscopy) é um método que surgiu como alternativa para a estimativa dos teores de nutrientes, de uma maneira mais rápida, menos onerosa e menos poluente. Para que a técnica seja empregada com boa acurácia e precisão, a cada nutriente de interesse é necessário conhecer qual a melhor combinação de pré-processamento espectral e modelo de calibração multivariada que deve ser utilizado. O presente trabalho tem como objetivo avaliar o uso do NIRS para estimar a concentração de Nitrogênio presente em tecido foliar de milho através de diferentes técnicas de pré-processamento e calibração multivariada. Para desenvolver os modelos de predição, serão testados dois métodos de calibração multivariada: *Partial Least Squares Regression* (PLSR) e *Support Vector Machine* (SVM). Os modelos serão calibrados por validação cruzada usando uma divisão aleatória em segmentos. Os valores de N preditos por cada modelo serão comparados aos valores de referência e as estatísticas de quantificação da acurácia foram calculadas: coeficiente de determinação ( $R^2$ ), relação entre o desempenho e a distância interquartil (RPIQ) e erro médio quadrático de predição (RMSE).

**PALAVRAS-CHAVE:** Espectroscopia de infravermelho próximo; pré-processamentos espectrais; predição de nitrogênio

## NEAR INFRARED SPECTROSCOPY AS ALTERNATIVE TO ESTIMATE THE NITROGEN CONTENT IN CORN VEGETABLE TISSUE

**ABSTRACT:** The methods traditionally used to analyze nutrient concentration in plant tissue and grains used to be expensive, inefficient and represent risks due to the use of chemical products. The spectroscopy visible and near infrared VIS/NIR (Near Infrared Spectroscopy) is a method that emerged as an alternative to estimate nutrient content, in a faster, cheaper and less pollutant way. To apply the technique accurately and precisely, for each nutrient of interest it is necessary the knowledge of the best combination of spectral pre-processing and multivariate calibration model that should be used. This present work aims to evaluate the use of NIRS to estimate the concentration of Nitrogen present in maize leaf tissue through different pre-processing and multivariate calibration techniques. To develop the prediction models, two multivariate calibration methods will be tested: *Partial Least Squares Regression* (PLSR) and *Support Vector Machine* (SVM). The models will be calibrated by cross-validation using a random division into segments. The N values predicted by each model will be compared to the reference values and the statistics of quantification of the accuracy were calculated: coefficient of determination ( $R^2$ ), proportion between performance and interquartile distance (RPIQ) and mean squared error of prediction (RMSE).

**KEYWORDS:** Near infrared spectroscopy; spectral preprocessing; nitrogen prediction

**INTRODUÇÃO:** A adequada nutrição mineral de plantas é de fundamental importância para que altos rendimentos possam ser alcançadas. Neste contexto, a necessidade de estudos sobre as demandas nutricionais de várias culturas de lavoura e a quantificação de nutrientes nos tecidos e nos grãos são parâmetros de extrema importância para auxiliar na compreensão do aproveitamento e na dinâmica de nutrientes nas plantas.

Atualmente, os métodos tradicionais de análise nutricional (laboratoriais) ainda são os mais utilizados e apresentam diversas limitações, dentre as quais estão o custo elevado por amostra, a baixa eficiência operacional e os riscos ambientais, devido ao uso de reagentes químicos poluentes. Desta forma, novos métodos de análise se mostram promissores, os quais são menos onerosos, apresentam maior eficiência operacional e sem geração de poluentes. Dentre essas novas metodologias emergentes, se destaca o emprego da espectroscopia do visível e do infravermelho próximo – VIS/NIR (*Near Infrared Spectroscopy*), que vem sendo utilizada desde os anos de 1990 na agricultura para análise de atributos físico-químicos do solo.

O método da espectroscopia - NIR realiza estimativas de moléculas orgânicas com base na reflectância da radiação eletromagnética, pois, por meio de radiação incidente sob a amostra, é fornecida uma quantidade de energia capaz de vibrar as ligações químicas que unem os átomos (FERREIRA, 2017). Assim, os resultados destas avaliações podem ser convertidos matematicamente em valores de teores de nutrientes, porém uma das inúmeras dificuldades para a utilização desses métodos são a ausência de curvas de calibração. Apesar das inúmeras vantagens em relação aos métodos tradicionais de análise nutricional em plantas, a espectroscopia de NIR ainda não é comumente aplicada para esse fim, embora trabalhos já demonstrem a capacidade dessa tecnologia em estimar teores de nutrientes em amostras de tecido vegetal.

Assim, o objetivo do presente trabalho foi avaliar o uso da espectroscopia de infravermelho próximo (NIR) para estimar a concentração de nitrogênio (N) em tecido vegetal da cultura do milho, por meio de diferentes técnicas de pré-processamento e calibração multivariada.

**MATERIAIS E MÉTODOS:** As amostras vegetais de plantas de milho utilizadas foram provenientes de inúmeros experimentos de campo conduzidos na Estação Experimental Agronômica da Universidade Federal do Rio Grande do Sul (EEA/UFRGS), localizada no município de Eldorado do Sul (RS), entre os anos de 2015 e 2019. O local de condução dos experimentos possui solo caracterizado como Argissolo Vermelho Distrófico típico (STRECK et al., 2018). O clima é classificado como subtropical, com inverno seco e verão úmido (Cfa), segundo classificação climática de Koppen (BERGAMASCHI et al., 2003).

Os tratamentos utilizados nos experimentos objetivaram gerar variabilidade de teores de nitrogênio no tecido vegetal. Para isso, utilizou-se as seguintes doses de nitrogênio (N): sem N, 25, 50, 75, 100, 120, 150 e 200 kg ha<sup>-1</sup>. As coletas de para análise laboratorial foram realizadas sempre no estágio de florescimento do milho (Estádio R1), sendo amostradas as plantas em uma área de 0,50 m<sup>2</sup>. As amostras foram então secas em estufa com circulação de ar forçado, sob temperatura de 65-70°C, e, posteriormente, moídas em frações de até 2,5mm.

Posteriormente, foram conduzidas análises químicas para determinar as concentrações de N (em percentagem) nas amostras, pelo método da solubilização sulfúrica e semi-micro Kjeldahl. A técnica consiste em realizar a solubilização úmida, seguida por destilação a vapor e titulação para a quantificação do amônio. A solubilização sulfúrica (H<sub>2</sub>SO<sub>4</sub> + catalisadores) transforma as proteínas e aminoácidos do tecido vegetal em N-NH<sub>4</sub><sup>+</sup>, o qual é destilado e complexado em ácido bórico com indicador misto e titulado com solução padronizada de H<sub>2</sub>SO<sub>4</sub> diluído (TEDESCO et al., 1995).

As análises espectroscópicas nas amostras de plantas moídas foram realizadas no Laboratório Federal de Defesa Agropecuária do Ministério da Agricultura, Pecuária e Abastecimento (MAPA) (Lanagro - RS), localizado em Porto Alegre (RS). A determinação da assinatura espectral das amostras foi realizada na faixa de 400 e 1000 nm do espectro eletromagnético, utilizando espectrômetro modelo FTIR Nicolet 26700 (Waltham, Massachusetts, EUA). O modo de leitura com o espectrômetro foi com a refletância difusa, com uma esfera de integração, com resolução de 2 cm<sup>-1</sup> e 60 leituras para cada espectro. Após a aquisição dos espectros, os dados foram submetidos a três técnicas de pré-processamento espectral: *Detrend* (DET), *Savitsky-Golay derivative* (SGD) e *Standard Normal Variate* (SNV), visando destacar as feições de interesse e melhorar as predições do teor de N no tecido vegetal.

Por fim, desenvolveu-se os modelos de predição e, para isso, foram utilizados dois métodos de calibração multivariada: *Partial Least Squares Regression* (PLSR) e *Support Vector Machine* (SVM). Os modelos foram calibrados por validação cruzada usando uma divisão aleatória em segmentos. Os valores de teor de N preditos por cada modelo foram comparados aos valores de referência (valores determinados pelas análises laboratoriais) e as seguintes estatísticas de quantificação da acurácia foram calculadas: coeficiente de determinação ( $R^2$ ), relação entre o desempenho e a distância interquartil (RPIQ) e erro médio quadrático de predição (RMSE). Verum et al. (2015) relatam que valores de  $R^2$  superiores a 0,75 podem ser classificados como “satisfatórios”; valores de  $R^2$  entre 0,50 e 0,75 como “moderadamente satisfatórios” e valores inferiores a 0,50 como “insatisfatórios”. Em relação à distância interquartil (RPIQ), valores maiores que 3 são considerados como “satisfatórios”; entre 1,50 e 1,90 moderadamente satisfatório; e valores menores que 1,50 são considerados “insatisfatórios”. Todas as análises acima descritas foram realizadas por meio do software R (R CORE TEAM, 2021).

**RESULTADOS E DISCUSSÃO:** Todos os modelos testados (pré-processamento e métodos de calibração multivariada) apresentaram valores do coeficiente de determinação ( $R^2$ ) satisfatórios, sendo que o método SVM foi aquele que apresentou os melhores resultados ( $R^2=0,99$ ), em combinação com todos os pré-processamentos (Tabela 1), resultados semelhantes aos de Verum et al., 2015. Os maiores erros médios absolutos (RMSE) foram verificados nos modelos em que foi utilizado o método PLSR, e, nesse método, o pré-processamento que mais reduziu o RMSE foi o *Savitzky-Golay Derivative* (Tabela 1).

**TABELA 1.** Desempenho das predições do teor de N em tecido vegetal para modelos utilizando a faixa espectral do NIR, método multivariado, pré-processamento espectral e conjunto de dados (tecido). **Performance of plant tissue N content predictions for models using the NIR spectral range, multivariate method, spectral pre-processing and dataset (tissue).**

Faixa Espectral	N amostras	Cultura	Modelo	Pré-processamento	Elemento	Material	$R^2$	RMSE	RPIQ
NIR	141	Milho	PLSR	Original	N	Tecido	0.80	0.80	3.08
NIR	141	Milho	PLSR	Detrend	N	Tecido	0.81	0.78	3.14
NIR	141	Milho	PLSR	Standard Normal Variate	N	Tecido	0.81	0.78	3.12
NIR	141	Milho	PLSR	Savitzky-Golay Derivative	N	Tecido	0.92	0.50	4.95
NIR	141	Milho	SVM	Original	N	Tecido	0.99	0.17	17.73
NIR	141	Milho	SVM	Detrend	N	Tecido	0.99	0.16	14.87
NIR	141	Milho	SVM	Standard Normal Variate	N	Tecido	0.99	0.17	14.67
NIR	141	Milho	SVM	Savitzky-Golay Derivative	N	Tecido	0.99	0.17	14.64

A Relação entre o desempenho interquartil (RPIQ) foi mais alta nos modelos utilizando o método SVM. Assim, os valores encontrados neste estudo são considerados satisfatórios para a predição de N em tecido foliar, sendo que o modelo que apresentou maior precisão foi o SVM com os pré-processamentos *Standard Normal Variate* (SNV) e *Savitzky-Golay Derivative* (SGD) (Figura 1).


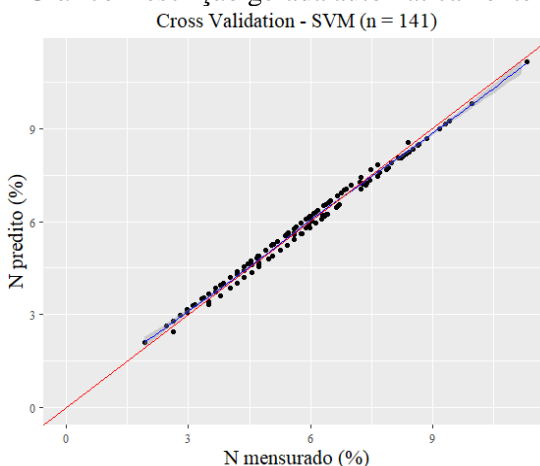


Gráfico Descrição gerada automaticamente



Gráfico, Gráfico de dispersão Descrição gerada automaticamente

**FIGURA 1.** Valores determinados pela análise química e valores preditos pela espectroscopia na faixa espectral do NIR utilizando o modelo SNV com o pré-processamento SNV (a) e SGD (b). **Values determined by chemical analysis and values predicted by spectroscopy on NIR spectral range using SNV model with pre-processing SNV (a) and SGD (b).**

**CONCLUSÃO:** A espectroscopia de refletância difusa foi capaz de prever com acurácia satisfatória os teores de N nas amostras foliares de milho. Os melhores resultados foram observados utilizando o método multivariado SVM e pré-processamento *Detrend*.

#### AGRADECIMENTOS:

Os autores agradecem à Universidade Federal do Rio Grande do Sul (UFRGS), ao CNPQ, ao Grupo de Estudos em Agricultura Digital (GEAD), e ao Laboratório Federal de Defesa Agropecuária (Lanagro-RS), por todos os incentivos e disponibilidade em utilizar suas instalações e equipamentos.

#### REFERÊNCIAS

BERGAMASCHI, H. et al. **Clima da Estação Experimental da UFRGS (e região de abrangência).** Porto Alegre: UFRGS, 2003, 78p.

FERREIRA, P. H. **Redução da dimensionalidade para estimativa de teores de nutrientes em folhas e grãos de soja com espectroscopia no infravermelho.** Universidade Estadual de Ponta Grossa, 2017.

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.

TEAM, R. Core. 2020. **R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna, Austria.** Disponível em: <https://www.R-project.org>. Acesso em 15 de abril de 2022.

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.

TEDESCO, M. J.; GIANELLO, C.; BISSANI, C. A.; BOHNEN, H.; VOLKWEISS, S. J. Análise de solo, plantas e outros materiais. 2.ed. Porto Alegre, Departamento de Solos da Universidade Federal do Rio Grande do Sul. 1995. 174p. **Boletim Técnico de Solos**, v.5.

VERUM, K.; SUDDUTH, K. A.; KREMER, R. J.; KITCHEN, N. R. Estimating a soil quality index with VNIR reflectance spectroscopy. **Soil Science Society of America Journal**, v.79, p.637-649, 2015.

# MANEJO DE GRAMÍNEA UTILIZANDO IMAGEM DE SENSOR ÓPTICO EMBARCADO EM VEÍCULO AÉREO NÃO TRIPULADO (VANT)

RONILSON DE SOUZA SANTOS<sup>1</sup>; JOIRO JORGE VILAR SOUZA <sup>2</sup>; DÉBORA CAROLINE ARAÚJO DE JESUS <sup>3</sup>; BRENO DA SILVA SANTOS<sup>4</sup>; RADMIR ARAÚJO DE SOUZA <sup>5</sup>

<sup>1</sup>ENGEHEIR AGRÔNOMO, PROFESSOR - FAC. DE ENGENHARIA AGRONÔMICA, UFPA, Campus de Altamira. rrsantos@ufpa.br / (93) 9 8123-0266; <sup>2</sup>ENGEHEIR AGRÔNOMO, GRADUADO - FACHOLLI SEMENTES, Altamira; <sup>3</sup>ESTUDANTE, GRADUANDa - FAC. DE ENGENHARIA AGRONÔMICA, UFPA, Campus de Altamira; <sup>4</sup>ESTUDANTE, GRADUANDO - FAC. DE ENGENHARIA AGRONÔMICA, UFPA, Campus de Altamira; <sup>5</sup>ESTUDANTE, GRADUANDO - FAC. DE ENGENHARIA AGRONÔMICA, UFPA, Campus de Altamira

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** A pecuária brasileira detém o maior rebanho comercial do mundo. O objetivo deste trabalho foi caracterizar o manejo da forrageira em sistema de pastejo extensivo em três diferentes glebas, mediante dados coletados em campo, correlacionando-os com o Índice de Vegetação por Diferença Normalizada-NDVI. O experimento foi conduzido de agosto a novembro de 2019, no município de Altamira, PA, a unidade experimental foi de 28,8 hectares (ha), subdivididas em três glebas medindo 9,6 ha cada gleba, denominadas de G-1, G-2 e G-3. O trabalho consistiu-se no imageamento da área utilizando um par de sensores ópticos passivos no espectro do visível (RGB) e infravermelho próximo (NIR), embarcados em Veículo Aéreo Não Tripulado-VANT, visando avaliar a dinâmica temporal do estado vegetativo da cultura, a partir da análise do NDVI obtido durante o citado período, correlacionando-os com produtividade e densidade do solo. Os dados agronômicos coletados foram processados no software de análise geoestatísticas GS+ e as imagens processadas no software fotogramétrico Agisoft Metashape. Os resultados de NDVI médios para o período, variaram de 00 a 00, a densidade do solo-DS variaram de 1,26 g.cm<sup>-3</sup> a 1,67 g.cm<sup>-3</sup>; a produtividade variou de 10,130 t.ha<sup>-1</sup> a 16,870 t.ha<sup>-1</sup>, com todas as variáveis possuindo forte índice de dependência espacial.

**PALAVRAS-CHAVE:** Bovinocultura de corte; manejo de pastagem; NDVI

## GRASS MANAGEMENT USING IMAGE OF OPTICAL SENSOR EMBARKED IN NON-CREATED AIR VEHICLE (UAV)

**ABSTRACT:** Brazilian livestock has the largest commercial herd in the world. The objective of this work was to characterize the grass management in an extensive grazing system in three different plots, using data collected in the field, correlating them with the Normalized Difference Vegetation Index-NDVI. The experiment was conducted from august to november 2019, in the Altamira County PA, the experimental unit was 28.8 hectares (ha), subdivided into three plots, measuring 9.6 ha each plot, called G-1, G-2 and G-3. The work consisted of imaging the area using a pair of passive optical sensors in the visible (RGB) and near infrared (NIR) spectrum, boarded onto an Unmanned Aerial Vehicle-UAV, in order to evaluate the temporal dynamics of the vegetative condition crop, from the NDVI analysis, obtained during the season showed, correlating them with productivity and soil density. The agronomic data collected were processed in the GS+ geostatistical analysis software and the images processed in the Agisoft Metashape photogrammetric software. The average NDVI results for the period ranged from 00 to 00, the soil-DS density ranged from 1.26 g.cm<sup>-3</sup> to 1.67 g.cm<sup>-3</sup>; productivity ranged from 10,130 t.ha<sup>-1</sup> to 16,870 t.ha<sup>-1</sup>, with all variables having a strong spatial dependence index.

**KEYWORDS:** Beef cattle; pasture management; NDVI

**INTRODUÇÃO:** A produção de gado de corte brasileira é destaque no cenário mundial, pois, o país, detém o maior rebanho comercial do mundo. Segundo a EMBRAPA agrobiologia (2017), no Brasil, existem aproximadamente 200 milhões de hectares de pastagens nativas ou implantadas, dos quais, estima-se que, cerca

de 130 milhões estejam degradados e necessitem de alguma intervenção para reverter o estado em que se encontram.

Conceitualmente, a degradação da pastagem, configura-se pela redução acentuada e contínua da produtividade da gramínea, no decorrer do tempo (DIAS-FILHO, M. B., 2017).

Uma das formas para reduzir o atraso entre a coleta de informação e a intervenção, pode ser viabilizada com o uso de sensores e equipamentos de análise agronômica, embarcados em algum meio de transporte, entre estes, estão os Veículos Aéreos Não Tripulados-VANT, os quais são capazes de coletar informações espectrais dos alvos imageados.

De acordo com Holm et al. (1987), as plantas, durante o processo de fotossíntese, absorvem e refletem luz solar na faixa de ondas entre o visível, 360 nm a 760 nm, bem como, na faixa do infravermelho próximo, 760 nm a 1300 nm.

Quando a planta se torna desidratada ou doentia, a camada esponjosa desintegra e a planta deixa de refletir o máximo de luz NIR, aumentando a quantidade de luz vermelha (visível) refletida. Assim, uma combinação linear da refletividade NIR e refletividade do vermelho, deve proporcionar um excelente contraste entre a planta e o solo e até mesmo plantas saudias e plantas doentias. (AGRIBOTIX, 2015).

Portanto, o objetivo deste trabalho foi caracterizar o manejo da forrageira em sistema de pastejo extensivo mediante dados agronômicos, coletados em campo, correlacionando-os com o Índice de Vegetação por Diferença Normalizada-NDVI, durante o período climático conhecido como verão amazônico.

**MATERIAIS E MÉTODOS:** O trabalho foi conduzido no sitio JG, situado na cidade de Altamira-Pará, localizado sob as coordenadas N 9.655.393 m e E 355.981 m, com altitude média de 135 metros. A área da propriedade destinava-se à atividade pecuária, tendo 80% de sua área coberta com gramínea *Brachiaria brizanta cv. Marandu*. E, a área experimental, foi constituída de 28,80 hectares, subdividida em três glebas de 9,60 hectares cada, considerando características edafoclimáticas locais.



**Figura 1.** Mapa de situação e localização da área experimental

**Fonte:** Google Earth

Para a aquisição das imagens da área experimental e posterior geração do índice de vegetação por diferença normalizada-NDVI, foram realizados sobrevoos na área de produção utilizando uma Aeronave Remotamente Pilotada- RPA, asa móvel Marca/modelo 3DR Solo, equipada com um par de câmeras digitais, capazes de captar imagens no espectro do visível (RGB) e Infravermelho Próximo (Near Infrared).

Para manter a regularidade dos voos, os mesmos foram programados no software livre Mission Planner, versão 1.3.68, com os seguintes parâmetros: velocidade de deslocamento de 10 m.s<sup>-1</sup>, altitude de 60 m e sobreposição de imagens de 80% e 60% na longitudinal e lateral, respectivamente.

As imagens coletadas foram processadas no software Agisoft Metashape versão 1.5.4. A visita a campo para captação das imagens foi realizada mensalmente, entre os meses de agosto a novembro de 2019, sempre ao meio-dia, de sorte a evitar o auto sombreamento do dossel da cultura.

A partir da metodologia descrita por Sakamoto et al. (2011), calculou-se o Índice de Vegetação por Diferença Normalizada-NDVI, utilizando a Equação 1, permitindo gerar a planta de variabilidade espacial do citado índice.

$$\text{NDVI} = \frac{\text{NIR} - \text{RED}}{\text{NIR} + \text{RED}} \quad (\text{Equação 1})$$

Em que,

**NDVI**= Índice de vegetação por diferença normalizada;

**NIR** = Refletância do infravermelho próximo;

**RED** = Refletância da faixa do vermelho do espectro visível.

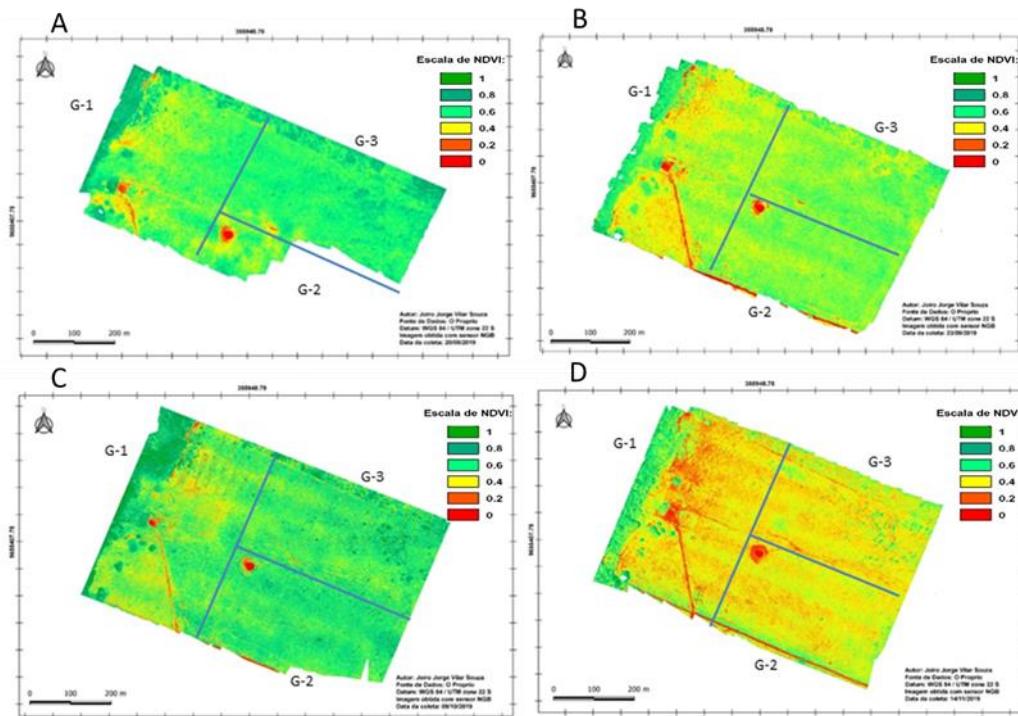
Para coleta dos dados agronômicos, em cada gleba, foram geo especializadas 60 (sessenta) células (grades) medindo cada uma 1.666 m<sup>2</sup>. Nestas, a partir do centro georreferenciado, foram coletadas amostras para análise de produtividade e a densidade do solo, com coleta 3 (três) pontos distintos, distanciadas há 5, 10 e 15 metros do mesmo, entre 0 e 30 cm de profundidade, com análise de acordo com metodologia descrita por EMBRAPA (2006) e EMBRAPA (2017), produtividade e densidade do solo, respectivamente.

Os resultados das análises dos dados agronômicos foram submetidos ao processamento geoestatístico utilizando o software GS<sup>+</sup> versão 7.0, no qual foi confeccionado e ajustado o variograma, com o melhor modelo escolhido a partir do maior coeficiente de determinação (r<sup>2</sup>). Foi calculado o índice de dependência espacial das variáveis, de acordo com os parâmetros definido por Zimback (2003).

Na análise temporal dos ortomosáicos, observa-se a dinâmica do NDVI entre os meses avaliados (Figura 2 - A, B, C e D). Nesta, inicialmente, observa-se a predominância do NDVI de 0,6 a 0,8 (Figura 1A), reduzindo para 0,2 ao longo do período de avaliação (Figura 1D). Esta variação pode está diretamente relacionada com a redução do índice pluviométrico na região, e evolução do período climático, denominado verão amazônico,



que inicia no mês de julho e estende-se até o mês de dezembro (Figura 2).



**RESULTADOS E DISCUSSÃO: Figura 2:** Ortomosaicos do NDVI, das coletas de imagens realizadas nos meses de agosto – A, setembro – B, outubro – C e novembro – D, de 2019 na área experimental.

**Fonte:** Próprio autor.

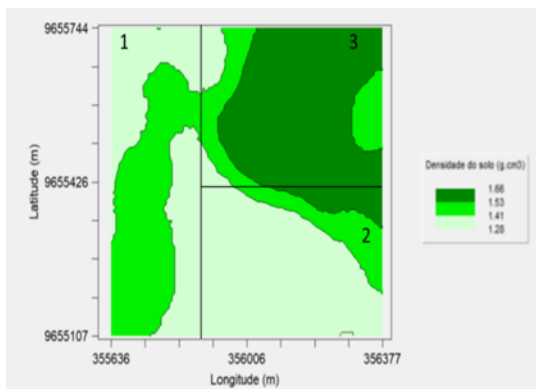
Nos resultados obtidos do ortomosaico da quarta coleta de dados (Figura 2D), nota-se que a gramínea refletiu quantidade maior de luz no comprimento de onda no vermelho, resultado do estresse hídrico ocasionado pelo período crítico do verão amazônico. Fato que, Holm et al. (1987), associou à mudança na estrutura celular das folhas, pois a reduzida quantidade de água no solo, proporciona o fechamento dos estômatos, ocasionando diminuição da fotossíntese.



**Figura 3:** Planta temático de interpolação dos dados 2D de vegetação espontânea e produtividade.

A produtividade variou de 10,7 a 14,4 t.ha<sup>-1</sup>, sendo a G-2 a gleba com pior resultado deste indicador agrônomo ( 10.7 t.ha<sup>-1</sup>), a G-1 obteve resultado intermediário com produtividade de ( 12.6 t.ha<sup>-1</sup>), enquanto a G-3 que obteve a maior produtividade ( 14.4 t.ha<sup>-1</sup>), foi também a área que obteve o maior NDVI (Figura 2) durante todo o período de condução do experimento, comprovando assim que, o citado índice mantém relação direta com o estado vegetativo da cultura, traduzindo-se em área de menor ou maior produtividade, a depender do nível de estresse.

A densidade do solo variou de 1,28 a 1,66 g.cm<sup>3</sup> (Figura 4) pode ter sido influenciada pelo teor de argila no solo. Ademais, de acordo com Reichert et al. (2003) para um solo de textura arenosa os resultados obtidos não são fatores limitantes para o desenvolvimento do sistema radicular das plantas.



**Figura 4:** Mapa temático da interpolação dos dados de densidade do solo e teor de argila da área experimental, respectivamente.

Sá, (2005), complementa e ratifica a afirmação de Reichert (2003), pois, segundo o autor, solos arenosos tendem a apresentar valores de densidade naturalmente mais elevados em relação a solos argilosos. Como exemplo, pode-se citar a densidade de  $1,5 \text{ g cm}^3$ , que, em um solo argiloso pode significar um elevado grau de compactação, enquanto em um solo arenoso pode significar solo solto.

**CONCLUSÃO:** A espacialização dos fatores agrônômicos avaliados possibilitaria a realização de um manejo mais assertivo na pastagem, minimizando desta forma o processo de degradação e beneficiando o desenvolvimento vegetativo da gramínea.

O manejo inadequado da gramínea reduziu a capacidade produtiva da cultura, desencadeando processo de degradação na pastagem e a incidência de vegetação espontânea na área manejada.

## REFERÊNCIAS

- AGRIBOTIX. **Imagens NDVI para agricultura**. Droneng, 2015. Disponível em <https://blog.droneng.com.br/imagens-ndvi-para-agricultura/> acessado em 02 de setembro de 2020.
- DIAS-FILHO, M. B. **Degradação de pastagens: o que é e como evitar**. Brasília, DF, EMBRAPA, 2017. p 10.
- EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. **Manual de métodos de análise de solo**. 3. ed. rev. e ampl. Brasília, DF, 2017.
- EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. **Método do quadrado para estimar a capacidade de suporte de pastagens**. Porto Velho, RO, 2006.
- EMBRAPA-AGROBIOLOGIA – Empresa Brasileira de Pesquisa Agropecuária. **Pastagens**, 2017. Disponível em: <https://www.embrapa.br/agrobiologia/pesquisa-e-desenvolvimento/pastagens> acessado em 10 de setembro de 2020.
- HOLM, A. M.? BURNSIDE, D. G. ? MITCHELL, A. A. The development of a system for monitoring trend in range condition in the arid shrublands of Western Australia. The **Rangeland Journal**, v. 9, n. 1, p. 14-20, 1987.
- REICHERT, J. M.; et al. Qualidade dos solos e sustentabilidade de sistemas agrícolas. **Ci. Amb.** ,27:29-48, 2003.
- SÁ, M. A. C de.; **Compactação do solo: consequências para o crescimento vegetal**-Planaltina, DF: EMBRAPA Cerrados, 2005.

SAKAMOTO, T. et al. Assessment of digital camera-derived vegetation indices in quantitative monitoring of seasonal rice growth. ISPRS. **Journal of Photogrammetry and Remote Sensing**, v. 66, n. 6, p. 872-882. 2011.

ZIMBACK, C.R.L. Geoestatística. Apostila didática, FCA/UNESP, jun. 2003. 25p.

## **2. Aplicação Localizada**

# UM ESTUDO DE CASO EM CITRUS: 6 ANOS DE ADUBAÇÃO EM DOSE FIXA E VARIADA

Luis Gustavo Mendes<sup>1</sup>; Marcelo Chan Fu Wei<sup>2</sup>; José Paulo Molin<sup>3</sup>

<sup>1</sup>Eng<sup>o</sup> Agrônomo, Mestre - Engenharia de Sistemas Agrícolas, USP/ESALQ - Piracicaba/SP. luis.gustavo.mendes383@gmail.com / ; <sup>2</sup>Eng<sup>o</sup> Agrônomo, Mestrando - Departamento de Engenharia de Biossistemas, USP/ESALQ - Piracicaba/SP; <sup>3</sup>Eng<sup>o</sup> Agrícola, Professor - Departamento de Engenharia de Biossistemas, USP/ESALQ - Piracicaba/SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** As tecnologias de agricultura de precisão auxiliam na gestão dos insumos nas culturas, buscando a sua otimização, maiores lucratividades e sustentabilidade de toda a cadeia produtiva. Algumas tecnologias vêm sendo avaliadas na citricultura resultando na otimização de aplicações de insumos em doses variadas. O objetivo deste trabalho foi comparar o efeito dos tratamentos da aplicação de calcário, nitrogênio, fósforo e potássio em doses fixas (DF) e variadas (DV) na produtividade em pomares de laranja ao longo de seis safras. O estudo foi conduzido entre os anos de 2011 e 2017 em dez talhões de aproximadamente 25 ha cada localizados na fazenda Rio Pardo, município de Iaras, SP (22°57'03,5"S; 48°39'37,4"W). O tratamento em DV não reduziu os volumes de aplicação de P, K e N quando comparadas às aplicações do tratamento DF, porém as eficiências produtivas foram maiores no tratamento em doses variadas. Os valores médios de produtividade no tratamento DV foram superiores em quatro safras.

**PALAVRAS-CHAVE:** laranja; larga escala; otimização de insumos

## A CASE STUDY IN CITRUS: 6 YEARS OF FERTILIZATION AT VARIABLE AND FIXED RATE

**ABSTRACT:** Precision agriculture assists the management of crop inputs, seeking its optimization, providing a greater profitability and sustainability of the entire production chain. Some technologies have already been evaluated in citrus, resulting in the optimization of inputs applications in variable rate. Thus, the objective of the work was to compare the effect of applying limestone, nitrogen, phosphorus and potassium at fixed (DF) and variable rate (DV) in orange orchards yield over six seasons. The study was conducted between 2011 and 2017 in ten plots of approximately 25 ha each located on the Rio Pardo farm, Iaras, SP (22°57'03.5 "S; 48°39'37.4" W). The DV treatment did not reduce the application volumes of P, K and N when compared to the DF treatment applications. However, the productive efficiencies were higher in the treatment in variable rates using precision agriculture concepts in the applications. The average values of productivity in the DV treatment were higher in four crops.

**KEYWORDS:** input optimization; large scale; orange

**INTRODUÇÃO:** As aplicações de insumos químicos em citros no Brasil baseiam-se em recomendações de décadas passadas, como de Raij et al. (1997), além da sua aplicação ser realizada de forma uniforme desconsiderando possíveis variabilidades intra-talhão. Entretanto, ciente de que a agricultura de precisão (AP) definida como uma estratégia de manejo que auxilia tomadores de decisão a partir da variabilidade predita do conjunto de dados espaciais, temporais e individuais coletados, processados e analisados (ISPA, 2019), torna-se necessário considerar a variabilidade inerente à cultura e local de implementação para que sejam tomadas as melhores decisões relacionadas à sua produção corroborando com os objetivos da AP, que buscam aprimorar o uso dos recursos, aumentar a produtividade, qualidade, retorno econômico e sustentabilidade de sua produção (ISPA, 2019). Apesar disso, na citricultura, poucos trabalhos como de Colaço e Molin (2017) foram realizados no Brasil e no mundo, avaliando o efeito da adoção de doses fixas e variadas na produtividade. Colaço e Molin (2017) realizaram um estudo de seis anos em dois talhões de laranja, com 25 ha cada, avaliando a sua produtividade em relação a doses fixas (DF) e variadas (DV) de nitrogênio (N), fósforo (P) e potássio (K). Trabalharam com arranjo de duas fileiras para cada tratamento ao longo dos dois talhões e concluíram que o tratamento em doses variadas resultou em maior eficiência no uso de insumos e produtividade de frutos. Diante

disso, sabendo que a adoção de técnicas de AP na citricultura ainda é baixa e que existem poucos estudos avaliando o efeito da aplicação de insumos em dose fixa e variada na produtividade de frutos de laranja, torna-se oportuno investigar o efeito da aplicação de insumos em DF e DV na produtividade de pomares de laranja em área total. A hipótese do trabalho é que a produtividade de frutos não será necessariamente afetada pela forma de aplicação de insumos, uma vez que a variabilidade intra-talhão pode ser mais ou menos acentuada dependendo do talhão. Dessa maneira, o objetivo do trabalho foi comparar o efeito dos tratamentos da aplicação de calcário, nitrogênio, fósforo e potássio em doses fixas e variadas na produtividade ao longo de seis safras em pomares de laranja.

**MATERIAIS E MÉTODOS:** O estudo foi conduzido entre os anos de 2011 e 2017 em dez talhões de aproximadamente 25 ha cada localizados na fazenda Rio Pardo, município de Iaras, SP (22°57'03,5"S; 48°39'37,4"W), com solo classificado como latossolo vermelho. Em 2008 foram implantados os pomares nos talhões de 1 a 8 com espaçamento entre fileiras de 6,8 m e entre plantas de 2,8 m. Em 2009 foram implantados os pomares nos talhões 9 e 10 com espaçamento entre fileiras de 6,8 m e entre plantas de 2,6 m. As variedades de copa utilizadas foram: (i) natal e (ii) valência e os porta-enxertos: (i) volkameriano e (ii) citrumelo swingle (Figura 1). Os dez talhões foram divididos em dois grupos para posteriormente receberem tratamento distintos, de dose fixa ou dose variada dos insumos químicos nitrogênio, fósforo, potássio e calcário (Figura 1).

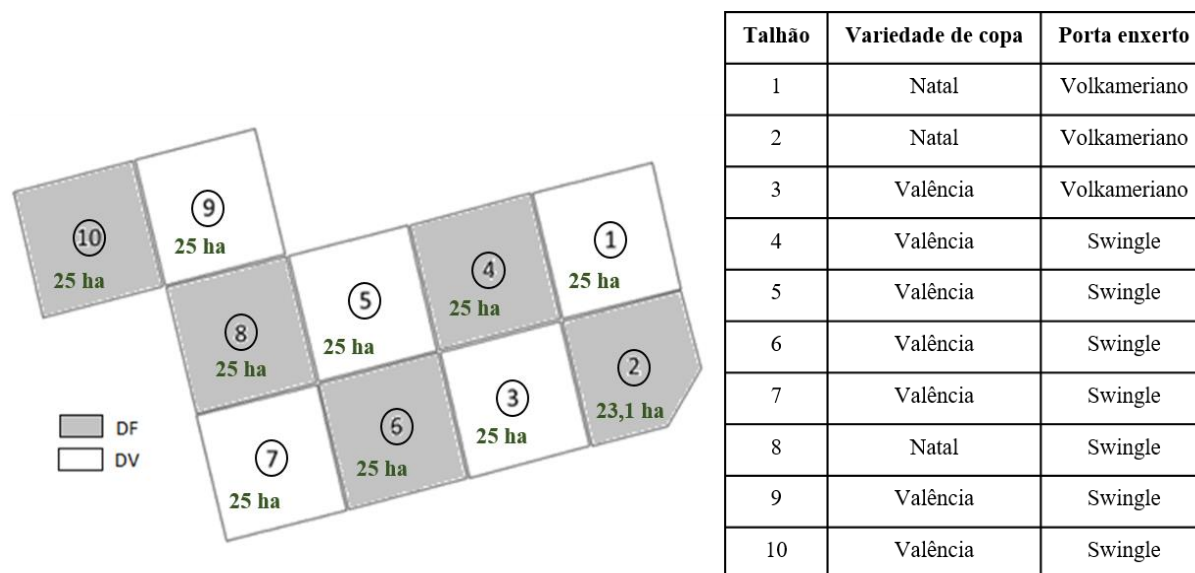


FIGURA 1. Distribuição dos talhões para condução de adubação de nitrogênio, fósforo, potássio e calcário à dose fixa (DF) e dose variada (DV) juntamente com a descrição da variedade de copa e porta-enxerto. **Plot distribution to conduct nitrogen, phosphorus, potassium and limestone fertilization at fixed (DF) and variable rate (DV) associated with the canopy and rootstock variety description.**

A amostragem de solo foi realizada anualmente entre os meses de abril e maio, após a aplicação das três parcelas de adubação, com uma grade amostral de uma amostra ha<sup>-1</sup> na profundidade de 0,2 m, sendo esta georreferenciada por um receptor GPS (Global Positioning System) de navegação modelo 62S (Garmin, Olathe, EUA) e composta por seis subamostras coletadas sob a projeção da copa das plantas em ambos os tratamentos. Entretanto, apenas para os talhões do tratamento DV, essa amostragem foi considerada para o cálculo das recomendações de adubação. Nos talhões do tratamento DF, as amostragens realizadas serviram para o monitoramento dos teores no solo e a adubação seguiu a recomendação de aplicação utilizada pela fazenda, guiada por uma amostra talhão<sup>-1</sup>, composta por 25 subamostras. As amostras de solo foram submetidas para análise química e física. A partir dos resultados das análises químicas do solo, foram calculadas as recomendações de aplicações de calcário, N, P e K para os dois tratamentos, DF e DV. As recomendações de calcário foram calculadas com o intuito de atingir o valor de saturação de bases em 70% (Raij et al., 1997) e as suas aplicações foram realizadas entre maio e junho. As adubações foram calculadas de forma distinta para os tratamentos: (a) DF, calculado segundo Raij et al. (1997) e (b) DV, calculado segundo Colaço e Molin (2017). Para que fosse possível a aplicação em taxa variável, foi necessário gerar os mapas de recomendação

a partir da análise geoestatística pelo programa Vesper 1.6 (University of Sidney, Sidney, AU) para posterior interpolação. A interpolação foi realizada adotando o seguinte critério considerando a dependência espacial entre as amostras: (a) presença (krigagem ordinária pelo programa Vesper 1.6 (University of Sidney, Sidney, AU) e (b) ausência (inverso da distância pelo programa QGIS (Open Source Geospatial Foundation, Beaverton, USA). Apesar das recomendações serem distintas, todas as aplicações foram parceladas em três vezes para os dois tratamentos: 1ª parcela (N, P e K) entre setembro e outubro, 2ª parcela (N, P e K) entre novembro e dezembro e 3ª parcela (N e K) entre fevereiro e março. A aplicação dos insumos nos tratamentos DV e DF foi realizada com a máquina adubadora de arrasto modelo Komander HD Full (Kamaq, Araras, BR) com um controlador hidráulico de vazão e um monitor para leitura dos mapas de recomendação Vcom 5.6 (Verion, Guarulhos, BR). Na aplicação nos talhões DF o recurso de taxa variada não era utilizado e a máquina era devidamente regulada para as doses fixas demandadas. O delineamento do experimento foi inteiramente casualizado composto por dois tratamentos e cinco repetições em uma série temporal de seis anos. Prosseguiu-se com o teste de comparações de média de Tukey a um nível de 5 % de significância para avaliar o efeito dos tratamentos na produtividade dos pomares de laranja. Toda a análise estatística foi realizada no programa R (R Core Team, 2018).

**RESULTADOS E DISCUSSÃO:** Os valores médios de N, P, K e calcário aplicados por tratamento e ano são apresentados na Figura 2. Os valores médios de N aplicados em DV, em valores absolutos, foram superiores aos da DF apenas em duas safras, enquanto que a quantidade média de P e calcário aplicada em DV foi superior à DF em quatro safras. Os valores médios aplicados de K foram superiores na DV em todas as safras. Considerando apenas a aplicação de insumos em DF e DV obtêm-se a percepção de que a DV promoveu um maior uso de insumos ocasionando em um aumento nas despesas da lavoura, que não é aceita por muitos, à primeira vista, como apresentado por Mattoso e Garcia (2006). Em relação aos insumos aplicados, o tratamento em doses variadas não proporcionou reduções no uso de fertilizantes nitrogenados e potássicos, contrastando com os encontrados na literatura por Aggelopoulou et al. (2010), Faulin (2010) e Colaço e Molin (2017). Entretanto, ressalta-se que a aplicação da DF e DV foram recomendadas por métodos distintos, ou seja, para efeito de comparação entre DF e DV é necessário avaliar a sua produtividade, que é o resultado das aplicações, e não observar apenas os valores absolutos aplicados. Para o caso do potássio, os maiores valores aplicados no tratamento DV pode estar relacionado com as equações de recomendações antigas utilizadas e a dinâmica deste elemento no solo, principalmente quanto à imobilização e fixação, o que acarreta na dificuldade de seu mapeamento sendo encontradas grandes variações em curtas distâncias. Para o caso do calcário, as maiores aplicações podem estar relacionadas a necessidade de elevação dos teores de V% para níveis altos na cultura da laranja (Raij et al., 1997), uma vez que nos primeiros anos do experimento os teores no solo estavam baixos necessitando de doses maiores deste elemento.

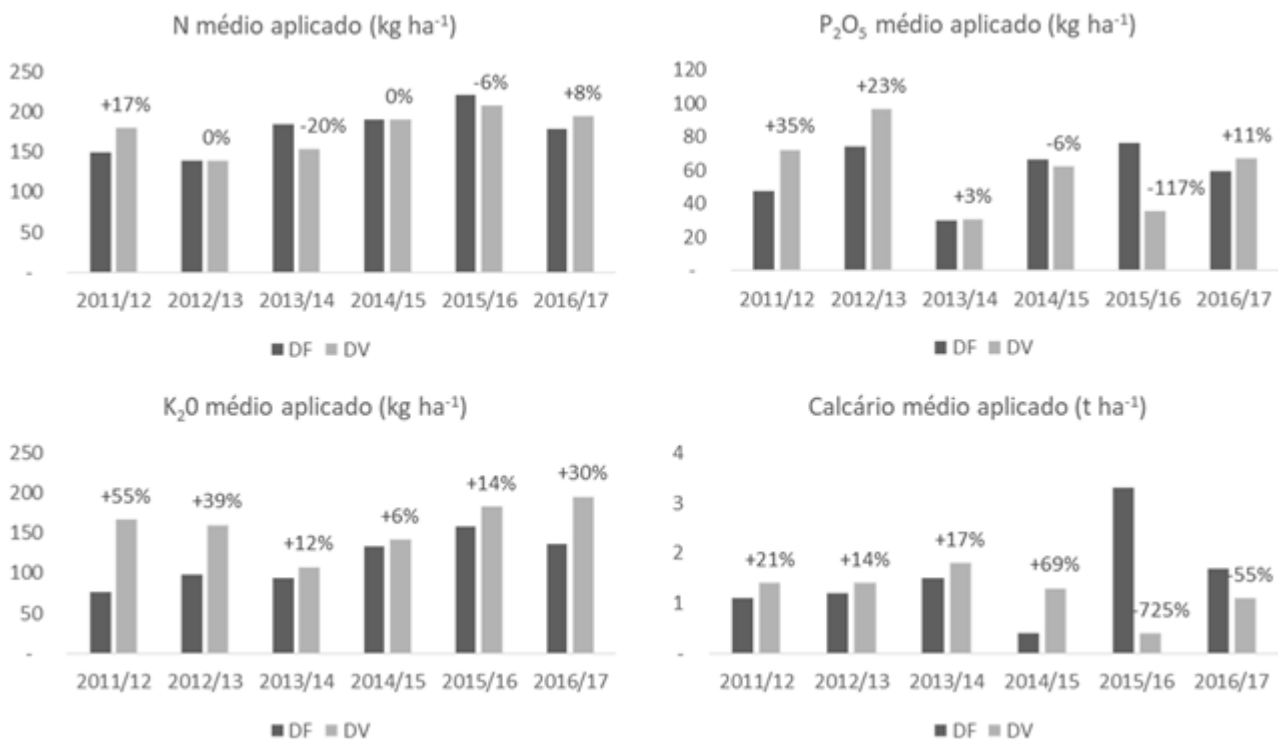


FIGURA 2. Valor médio de insumos aplicados nos tratamentos DF e DV durante seis anos e diferenças das quantidades aplicadas no tratamento DV em comparação ao DF. **Average total amounts of inputs applied in DF and DV treatments over six years and differences in quantities applied in DV treatment compared to DF.**

A partir dos valores médios de produtividade apresentados na Figura 3, independentemente do tratamento, observa-se um aumento gradual ao longo da safra, resultado esperado uma vez que os pomares em fase de crescimento tendem a produzir mais frutos por planta ao longo do tempo. Todas as safras estudadas apresentaram diferença estatística ao nível de 5% de significância entre seus tratamentos. As safras 2012/2013, 2013/2014, 2015/2016 e 2017/2018 apresentaram valores médios de produtividade no tratamento DV superiores à DF em aproximadamente 26%, 7%, 16% e 21% respectivamente. Enquanto que nas safras 2014/2015 e 2016/2017, os valores médios de produtividade no tratamento DF apresentaram valores estatisticamente superiores que o tratamento em DV em aproximadamente 18% e 13%, respectivamente. Colaço e Molin (2017) também apresentaram aumentos em produtividade da ordem de 13,1% em áreas que receberam o tratamento em doses variadas, porém analisando as produtividades dos tratamentos, em dois dos quatro anos avaliados os autores também obtiveram produtividades menores para este tratamento. As produtividades do tratamento DV se mantiveram mais homogêneas nos talhões que receberam doses variadas ao longo dos anos, assim como apresentado por Lopes (2010). Observando as Figuras 2 e 3 percebe-se que quando as aplicações de N foram superiores nos tratamentos com DF, as suas produtividades médias apresentaram resultados significativamente superiores à DV. Este fato pode ser explicado uma vez que o N é um elemento extremamente importante e relacionado com a produtividade da cultura da laranja cultivada em solos tropicais (Cantarella et al., 2003). No entanto, o mesmo não acontece para K e P. Isto deve ter ocorrido porque K e P apresentam maior importância para as características qualitativas dos frutos de laranja ao invés das características quantitativas (Quaggio et al., 2006).






FIGURA 3. Produtividade média de laranjas ( $t\ ha^{-1}$ ) por tratamento (dose fixa e variada) ao longo de seis safras. Letras minúsculas diferentes por safra significam que as produtividades médias foram estatisticamente diferentes entre si ao nível de 5% de significância pelo teste de comparação múltipla de Tukey. **Average orange productivity ( $t\ ha^{-1}$ ) per treatment (fixed and variable rate) over six crops. Different lower case letters per harvest mean that the average yields were statistically different at the 5% level of significance by Tukey's multiple comparison test.**

A eficiência dos fertilizantes, como utilizado por Colaço e Molin (2017), é a razão entre os valores da produtividade em cada tratamento e quantidade aplicada de cada insumo. De maneira geral, o tratamento em DV utilizou maiores quantias de fertilizantes, porém também produziu maiores quantidades de frutas de laranja. Os fertilizantes nitrogenados foram utilizados de maneira mais eficiente no tratamento DV em todos os anos do experimento avaliado, sendo 19% mais eficiente na conversão de nitrogênio para quilos de laranja por hectare no ano de 2014/15. Os fertilizantes fosfatados apresentaram menores eficiências nos três primeiros anos do experimento (Figura 4) e maiores eficiências a partir da safra de 2014/15. Uma hipótese seria que o nível baixo desse elemento no solo fez que com fossem necessárias maiores aplicações deste nutriente nos anos iniciais (Figura 3) a fim de suprir a demanda do solo. No caso dos fertilizantes potássicos, com exceção do ano de 2014/15, todas as eficiências foram maiores no tratamento DF. Entretanto, apesar do uso mais eficiente de P e K, de modo geral, nas doses variáveis, deve-se lembrar que estes elementos são mais relacionados aos aspectos qualitativos do que quantitativos dos frutos, como já estudado por Quaggio et al. (2006). O calcário seguiu uma tendência de menores eficiências nos quatro primeiros anos do tratamento DV, uma vez que, para atingir maiores teores no solo foram necessárias maiores aplicações iniciais e a partir do ano 2015/16 em diante sua eficiência foi maior no DV.



FIGURA 4. Eficiência do uso de fertilizantes e corretivos nos tratamentos à dose fixa (DF) e variada (DV). **Fertilizers and soil amendments use efficient under fixed (DF) and variable rate (DV).**

**PERSPECTIVAS FUTURAS:** As regressões utilizadas para o cálculo das equações de recomendação de adubação utilizadas na metodologia desse trabalho, de Rajj et al. (1997), são genéricas e globais e merecem ser revistas e substituídas por recomendações locais, que contemplem particularidades presentes nos pomares comerciais das diversas regiões produtoras, ou mesmo em nível de unidade de produção (fazenda). Além disso, sugere-se também realizar análises qualitativas dos frutos por tratamento, uma vez que existe um apelo por frutos com melhores qualidades sensoriais analisando características como teor de Brix, porcentagem de suco e acidez.

**CONCLUSÃO:** O tratamento em DV não reduziu os volumes de aplicação de P, K e N quando comparado às aplicações do tratamento DF, porém as eficiências produtivas foram maiores no tratamento em doses variadas. Os valores médios de produtividade no tratamento DV foram superiores em quatro safras.

#### REFERÊNCIAS

AGGELOPOULOU, K. D.; PATERAS, D.; FOUNTAS, S.; GEMTOS, T. A.; NANOS, G. D. Soil spatial variability and site-specific fertilization maps in an apple orchard. **Precision Agriculture**, v. 12, p. 118–129, 2011.

CANTARELLA, H.; MATTOS Jr., D.; QUAGGIO, J.A.; RIGOLIN A.T. Fruit yield of Valencia sweet orange fertilized with different N sources and the loss of applied N. **Nutrient Cycling in Agroecosystems**, v. 67, p. 215-223, 2003.

COLAÇO, A. F. & MOLIN, J. P. Variable rate fertilization in citrus: a long term study. **Precision Agriculture**, v. 18, p. 169-191, 2017.

FAULIN, G.D.C. *Influência da adubação em doses variadas na produtividade e no estado nutricional da cultura do café*. 2010. 103 f. Tese (Doutorado em Fitotecnia). Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, Brasil.

INTERNATIONAL SOCIETY OF PRECISION AGRICULTURE (ISPA). Precision Ag Definition. Disponível em: < <https://ispag.org/about/definition>>.

LOPES, F. de A. *Adubação em doses variadas em citros*. 2010. 76 p. Dissertação (Mestrado em Máquinas Agrícolas). Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, Brasil.

MATTOSO, M. J. & GARCIA, J. C. Análise econômica da agricultura de precisão. In: CONGRESSO BRASILEIRO DE AGRICULTURA DE PRECISÃO, 2., 2006, São Pedro, SP. *Anais...* Piracicaba: USP: ESALQ, 2006.

QUAGGIO, J.A.; MATTOS Jr., D., CANTARELLA, H. Fruit yield and quality of sweet oranges affected by nitrogen, phosphorus and potassium fertilization in tropical soils. **Fruits**, v. 61, p. 293-302, 2006.

RAIJ, B. van; CANTARELLA, H.; QUAGGIO, J.A.; FURLANI, A.M.C. **Recomendações de adubação e calagem para o Estado de São Paulo**. 2. Ed. Campinas: IAC, 1997. 279p. (IAC. Boletim Técnico, 100)

# 3. Economia

# **Agricultura de Precisão no Setor Sucroalcooleiro do Estado de São Paulo : análise produtiva, econômica e ambiental**

**João Vitor Costa Mazzi<sup>1</sup>; Adriana Estela Sanjuan Montebello<sup>2</sup>; Jeronimo Alves dos Santos<sup>3</sup>**

<sup>1</sup>Agroecólogo, Graduando no curso Bacharelado em Agroecologia da Universidade Federal de São Carlos (UFSCar) - Universidade Federal de São Carlos (UFSCar), Centro de Ciências Agrárias - CCA, UFSCar, Araras-SP. joao.mazzi@estudante.ufscar.br / (19) 9 9965-0000; <sup>2</sup>Doutor em Ciência ( Economia Aplicada), Docente da Universidade Federal de São Carlos (UFSCar) - Universidade Federal de São Carlos (UFSCar), Centro de Ciências Agrárias - CCA, UFSCar, Araras-SP; <sup>3</sup>Doutor em Ciência ( Economia Aplicada), Docente da Universidade Federal de São Carlos (UFSCar) - Universidade Federal de São Carlos (UFSCar), Centro de Ciências Agrárias - CCA, UFSCar, Araras-SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Essa pesquisa teve como objetivo analisar a atuação da agricultura de precisão no Setor Sucroalcooleiro do Estado de São Paulo, no que se refere às questões produtivas, econômicas e ambientais. Os objetivos foram: fazer um levantamento dos principais instrumentos da AP utilizados no Setor sucroalcooleiro e identificar os ganhos na produtividade, os principais aspectos econômicos e ambientais com a AP. Será utilizado o método de revisão bibliográfica para extrair dados em textos, artigos, jornais, revistas e base de dados oficiais na compilação das informações necessárias para responder ao problema e objetivos da pesquisa. Este trabalho teve como resultado a apuração produtiva, econômica e ambiental que os equipamentos da agricultura de precisão traz ao Setor Sucroalcooleiro do Estado de São Paulo. Sendo que gera para a produção ganhos de produtividade, diminuição de gastos e redução de impactos ambientais. Conclui-se que AP promove ganhos produtivos, econômicos e ambientais; no entanto, pode causar compactação do solo reduzindo produtividade, alto custo de aquisição e aprendizado. Desse modo, espera-se que este trabalho venha a corroborar com informações relevantes no auxílio de gestão e política do Setor.

**PALAVRAS-CHAVE:** Equipamentos; Produção; Impactos Ambientais

## **PRECISION AGRICULTURE IN THE SUGAR AND ALCOHOL SECTOR OF THE STATE OF SÃO PAULO: PRODUCTIVE, ECONOMIC AND ENVIRONMENTAL ANALYSIS**

**ABSTRACT:** This research aimed to analyze the performance of precision agriculture (PA) in the Sugar-cana and Ethanol Sector of the State of São Paulo-Brazil. We analyze economic, productive and environmental issues. The objectives were: to survey the main PA instruments used in the sugar-alcohol sector and identify gains in productivity, the main economic and environmental aspects with PA. The bibliographic review method will be used to extract data in texts, articles, newspapers, magazines and official databases in the compilation of the necessary information to answer the research problem and objectives. This work resulted in the production, economic and environmental assessment that precision agriculture equipment brings to the Sugar-Alcohol Sector of the State of São Paulo. Being that it generates productivity gains for the production, reduction of expenses and reduction of environmental impacts. It is concluded that PA promotes productive, economic and environmental gains; however, it can cause soil compaction, reducing productivity, high acquisition and learning costs. Thus, it is expected that this work will corroborate with relevant information in the management and policy assistance of the Sector.

**KEYWORDS:** Equipment ; Production ; Environmental impacts

**INTRODUÇÃO:** A partir da instituição da Comissão Brasileira de Agricultura de Precisão (CBAP), pelo Ministério da Agricultura, Pecuária e Abastecimento (MAPA) a AP ficou definida como um sistema de gerenciamento agrícola que se baseia na variação espacial e temporal da área produtiva, além de visar um retorno financeiro e sustentável maior (BRASIL, 2012, p. 6).

A origem do termo agricultura de precisão está fundamentada no fato de que as lavouras não são uniformes no espaço e nem no tempo. Assim foi necessário o desenvolvimento de estratégias para gerenciar os problemas advindo da desuniformidade das lavouras com variados níveis de complexidade (Molin, Amaral e Colaço, 2015). Nesse sentido, de que as lavouras são heterogêneas torna-se necessário que: a produção seja baseada no uso de dados; o manejo do solo deve ocorrer de acordo com as variações apresentada de cada talhão, de uma determinada área; o mapeamento e o monitoramento em tempo real e o uso de acurácia apropriada.

Nesse contexto, Thylén, Jurschik e Murphy (1997) consideraram que o mapa de produtividade é um dos métodos mais corretos para se ter a estimativa da heterogeneidade de uma lavoura. Ou seja, torna-se possível identificar quais são as áreas mais e as menos produtivas.

Há de se analisar que o retorno econômico depende de cada lavoura e das ações de cada produtor. Sendo que o primeiro passo deve ser a identificação da variabilidade espacial da lavoura (BERNARDI et al, 2014). De acordo com Zhang (2002) a produção agrícola pode ser afetada pelas seguintes variabilidades: de produção, campo, solo, cultura, fatores anômalos e manejo.

Atualmente o Brasil é o maior produtor mundial de cana de açúcar CONAB safra 2020/21. Uma característica importante da produção brasileira é que geralmente 50% é destinado a produção de etanol e os outros 50% para a produção de açúcar. Já em outros países a totalidade é direcionada para a produção de açúcar (CARVALHO e OLIVEIRA, 2006).

Em conformidade com a pesquisa realizada pela Embrapa (2014) às relações entre a tecnologias de Agricultura de Precisão e a produção de cana de açúcar tem como finalidade uma melhor qualidade, redução de custo da produção, como também se apresentar como uma ferramenta de otimização de manejo, minimização de custos operacionais e adequação ambiental.

Nessa lógica da evolução do setor canavieiro é possível identificar a preocupação do produtor com o meio ambiente. Visto que a Agricultura de Precisão otimiza a demanda de insumos no setor, focando a elevação produtiva por área e diminuindo os impactos ambientais (GREGO et al, 2014).

Em conformidade com os dados citados, o objetivo central dessa pesquisa foi analisar os aspectos produtivos, econômicos e ambientais da agricultura de precisão no Setor Sucroalcooleiro.

**MATERIAIS E MÉTODOS:** Este trabalho teve por metodologia a revisão bibliográfica através da documentação indireta, no que compete a análise produtiva, econômica e ambiental no Setor Sucroalcooleiro do Estado de São Paulo via Agricultura de Precisão.

De acordo Andrade (1993) e Espírito Santo (1992, p.82) a revisão bibliográfica faz com que haja por via de regra, à consulta de um elevado número de obras, sendo necessário, ao final, realizar uma seleção delas que serão mencionadas no trabalho. Contudo, deve-se constatar que todo trabalho que se utiliza o método de revisão bibliográfica, tem por necessidade considerar o que já se conhece para que haja avanço científico.

Nessa perspectiva, esse trabalho tem por finalidade analisar e compreender os resultados da Agricultura de Precisão no Setor Sucroalcooleiro do Estado de São Paulo no que diz respeito à análise produtiva, econômica e ambiental. Dessa forma, a base de dados utilizadas para fazer as revisões bibliográficas foram retirados de textos, artigos, jornais, revistas e bases de dados oficiais (Como MAPA, CONAB, Embrapa, base de periódicos, etc.).

**RESULTADOS E DISCUSSÃO:** Como resultado e discussão desta pesquisa foi realizado um levantamento analítico da análise produtiva, econômica ambiental e dos principais equipamentos no Setor Sucroalcooleiro do Estado de São Paulo via Agricultura de Precisão. Dentre os equipamentos estão: amostrador de solo; os sensores ópticos, térmicos, elétricos, mecânicos e pneumáticos; adubadora; plantadeira; irrigação por gotejamento; DGPS; GPS; RTK; sistemas embarcados; drones piloto automático; barra de luz e colhedora.

Nesse contexto, foi respeitado todas as fases produtivas desde o conhecimento do solo, passando pelo plantio e ações necessárias para o desenvolvimento da cultura, até a colheita mecanizada. Dessa forma, os equipamentos serão abordados do amostrador de solo, que realiza o conhecimento do substrato que receberá o cultivo até a colheitadeira mecanizada, a qual irá realizar a colheita da cana de açúcar. Em consonância com a sequência das pesquisas referenciadas abaixo.

Nesse sentido GREGO et al (2014), relata que a AP tem papel fundamental no aprimoramento da produtividade no setor sucroalcooleiro, visando o aumento da demanda interna e externa na produção de álcool e açúcar e ao mesmo tempo diminuição de impactos ambientais e expansão na produtividade. Ainda no aspecto produtivo os mesmos concluem que o uso das técnicas da AP elevam a produtividade média nas áreas próximas às plantas industriais já existentes; como também, instalação de usinas em regiões paulista com características adversas ao cultivo de cana-de-açúcar, nesse caso as técnicas serão ainda mais essenciais para os ganhos de produtividade e melhorias nos aspectos econômicos e ambientais.

Para CIRANI e MORAES (2011) a utilização da AP no setor sucroalcooleiro paulista está relacionada à adoção de novas tecnologias que possibilitam a elevação da produtividade, melhora nos produtos e métodos de gestão, além de contribuir com a preservação ambiental. Há de se destacar que o setor vem adotando as tecnologias da AP em grande escala; uma vez que a utilização de tecnologias menos impactantes ao meio ambiente, destinadas a elevar a produtividade e a rentabilidade do solo se tornará uma ferramenta indispensável para as agroindústrias sucroalcooleiras paulistas e brasileiras.

Nessa perspectiva SOUZA et al (2010) relata que uma alternativa de redução de custo para o setor sucroalcooleiro é a adoção da agricultura de precisão, visto que promove o conhecimento da variabilidade dos solos. Tal conhecimento pode ser adquirido através do uso do amostrador de solo. Uma vez que gera a detecção da variabilidade dos atributos do solo, além de trazer vantagens econômicas e de eficiência. Ademais, nos aspectos produtivos, econômicos e ambientais por meio de condições favoráveis em toda área da produção e o conhecimentos das mesmas o que acarreta a aplicação de insumo na dosagem e área correta que está ligado diretamente ao meio ambiente e a redução de custos (BAIO, 2007).

De acordo com LEDA, GONÇALVES E LIMA (2019) para se obter sucesso, qualidade e alta produtividade na produção canavieira é preciso que haja adequada relação entre fatores como: solo, clima, variedade da cana, plantas invasoras, doenças, pragas e nutrientes. É de suma importância a estimativa de produção, sendo fundamental o planejamento do setor, e que o monitoramento das áreas agrícolas e as estimativas de produção e produtividade realizadas com o uso de geotecnologias e sensoriamento remoto, tendem a colaborar expressivamente para se alcançar métodos de baixo custo e eficazes

Há de se analisar que os sensores ópticos, térmicos, elétricos, mecânicos e pneumáticos, além da produtividade trazem para o setor sucroalcooleiro aspectos econômicos e ambientais.

Os sensores ópticos de acordo com MOLIN (2010) tem potencial de retorno econômico, pois faz com que ocorra aplicação localizada de insumos em tempo real de acordo com as necessidades específicas dentro de cada lavoura. A partir disso, resulta na diminuição impactos ambientais associados à adubação nitrogenada em cana-de-açúcar, pois evita a pulverização desnecessária, a qual traz danos ambientais.

Para SCHIESSL (2018) os sensores térmicos analisam, calculam e preveem o desenvolvimento e produtividade do setor. Diante disso, é possível reduzir a aplicação de insumos, que por sua vez diminui os custos de produção. Como também, gerar diminuição de impactos ambientais. Uma vez que o sensoriamento remoto obtém informações da superfície terrestre.

Os sensores elétricos têm por finalidade caracterizar e analisar as propriedades físicas e químicas do solo (MUELLER et al., 2003). Nesse sentido, pode ser um mecanismo importante economicamente e ambientalmente. Assim como o sensores mecânicos os quais podem mensurar a compactação do solo e ser uma boa opção para medições em tempo real das propriedades físico-mecânicas dos solos. Bem como, os sensores pneumáticos pelo motivo terem o potencial de distinguir vários tipos de solo, níveis de umidade e estrutura/compactação do solo (SANCHES et al., 2011).

A agricultura de precisão é um vetor para a utilização eficiente dos fertilizantes levando em consideração a diversidade do solo e da lavoura, ou seja, visa à distribuição dos fertilizantes com maior exatidão e aplicando-

os adequadamente, com economia e maior preocupação com o meio ambiente (MOTOMIYA et al., 2011). Uma vez que o sensoriamento remoto por meio da AP, visa à distribuição adequada com maior precisão de acordo com a dosagem recomendada (MOLIN et al., 2010). Devido ao fato relacionado à aplicação em excesso deste nutriente, pode ocasionar impacto ambiental e perdas por lixiviação como também volatilização (CARNEIRO, 2015). Nesse sentido é que se encontra a adubadora, visto que a mesma realiza aplicação localizada e correta de fertilizantes e corretivos (MOLIN, 2015).

A utilização de plantadeira no cultivo de cana de açúcar gera diversos benefícios, seja eles produtivo tal como menor número de falha e maior número de perfilhos (JANINI, 2007), ou seja, no aspecto econômico tais como o aumento na longevidade dos canaviais e redução de custo (ROQUE et al, 2010). Segundo DUARTE JÚNIOR et al (2008) o ciclo da produção da cana de açúcar deve ser inteiramente mecanizado, mas é de suma importância o uso de equipamentos agrícolas com regulagens adequadas, pois, a partir disso ocorrerá diminuição no tempo de trabalho, maior eficiência, menor custo e um retorno econômico maior.

A utilização do sistema de irrigação da água por gotejamento faz com que haja gerenciamento de efluentes e resíduos. Uma vez que tem o objetivo de racionalizar o uso de recursos hídricos, priorizar a redução e reutilização de água/efluente. Por sua vez, resulta na economia de recursos hídricos, menor impacto ambiental, transformação de efluentes em adubos orgânicos (SCHIAVINATTO, 2020). Nesse sentido, o sistema de irrigação por gotejamento na produção de cana de açúcar é um caminho para ganhos nos aspectos produtivos, econômicos e ambientais.

Para BONGIOVANNI e LOWENBERG-DEBOER (2004) a sustentabilidade está relacionada com o princípio do uso do GPS. Pelo fato dos sistemas de auto direcionamento por satélites tais como GPS, RTK e DGPS, serem um mecanismo de reduções de custos e gerarem aumento de produtividade (SHIRAIISHI, 2013).

Há de se analisar que AP engloba o uso de inteligência embarcada, a automação e rede de sensores locais para o mapeamento de solos, tais práticas tornam a produção mais precisa e automatizada (OMEGA AGROSCIENCE, 2016).

Ademais, os sistemas embarcados traz a produção de cana de açúcar ganhos no escoamento e econômicos (FERNANDES, 2007). Mas, pode ocasionar efeitos prejudiciais ao meio ambiente, a exemplo a compactação do solo (SANTIAGO, 2020). A qual é definida como a compressão do solo não saturado, o que provoca uma reorganização estrutural das partículas e de seus agregados, gerando a elevação da densidade do solo e a redução na macroporosidade (STONE et al., 2002). Esse fenômeno é prejudicial à cultura, pois restringe o crescimento radicular, que por sua vez interfere no crescimento da planta e na produção de biomassa (ZOBIOLE et al., 2007).

De acordo com as informações do SINDAG (2018) o uso de drones na agricultura nos últimos anos estão relacionados à topografia, mapeamento e pulverização. Para BASTO (2015) os drones desempenham diversas funções tais como, análise de plantação, demarcação de plantio, acompanhamento da safra e do campo, pulverização, monitoramento do desmatamento, nascente de água, abertura de estradas, vigilância, focos de incêndios, telemetria/topografia.

Diante dessas funções torna evidente que os drones são de forma direta um mecanismo que auxilia para uma produção canavieira mais sustentável, pois analisa e identifica ações de desmatamento ambiental, danos nas nascentes hídricas, se há focos de incêndios e abertura de estradas em áreas mais adequadas. Além desse aspecto há o econômico, o qual os drones segundo LUCHETTI (2019) podem verificar problemas e atuar nas causas, dessa forma seriam reduzidas as perdas, o que por sua vez traria maiores ganhos na produção. Cabe ressaltar que o seu retorno sobre o investimento ocorre rapidamente (GOMES, 2018).

Segundo estudos o uso de piloto automático na abertura de sulcos no plantio de cana de açúcar apresenta um desempenho melhor tanto em percursos retos, quanto em percursos curvos. Dessa forma vem ganhando espaço no setor sucroalcooleiro (OLIVEIRA, 2009). Vale ressaltar que a tecnologia do piloto automático é a segunda mais utilizada nas usinas / destilarias paulista, cerca de 39% (CIRANI e MORAIS, 2010).

Já a implementação de barras de luz na produção canavieira diminui a sobreposição entre passadas consecutivas e otimiza a eficiência da operação agrícola (BAIO, 2001).

A mecanização da colheita de cana de açúcar trouxe benefícios e ganhos produtivos, econômicos e ambientais. Uma vez que aumentou a produtividade, reduziu os custos, diminuiu o tempo da colheita e reduziu os impactos ambientais; visto que dispensa a queimada de resíduos (ABREU et al., 2009).

**CONCLUSÃO:** Através da revisão bibliográfica foi possível analisar e identificar os equipamentos e as questões de produtividade, econômicas e ambientais da Agricultura de Precisão no Setor Sucroalcooleiro do Estado de São Paulo.

Dessa forma, foi possível verificar os seguintes equipamentos/maquinários: amostrador de solo, sensores ópticos, sensores térmicos, sensores elétricos, sensores mecânicos, sensores pneumáticos, adubadora, plantadeira, irrigação por gotejamento, DGPS, GPS, RTK, sistemas embarcados, drones, piloto automático, barra de luz e colhedora.

A AP traz para a produção uma adequada relação entre os fatores solo, clima, variedade da cana, plantas invasoras, doenças, pragas e nutrientes. Diante disso é possível ter ganhos produtivos, econômicos e ambientais. Além desses fatores há a comunicação direta entre os aspectos produtivos, econômicos e ambientais. Ou seja, a aplicação correta e na área certa; a diminuição no tempo da produção e na tomada de decisão; o uso eficiente de água e outras fontes a serem aplicadas nos canaviais; a diminuição de sobreposição das linhas; o aumento da longevidade dos canaviais, influenciam diretamente nesses três aspectos.

Espera-se que o levantamento de dados desse trabalho seja um mecanismo de aplicação e/ou desenvolvimento da agricultura de precisão para o Setor Sucroalcooleiro paulista, seja nos quesitos produção, econômico e ambiental. Posto que aborda os equipamentos implementados no Setor, além de apresentar suas ações na produção e no meio que está.

Todavia, torna-se necessário relatar a importância de se realizar outros levantamentos bibliográficos do assunto, bem como, verificar o uso de outras tecnologias tanto dentro do Estado de São Paulo quanto fora, pois o mesmo está sempre evoluindo. Diante disso, espera-se que o material seja uma ferramenta de estudo e que sirva de análise para o Setor Sucroalcooleiro paulista.

#### **AGRADECIMENTOS:**

Agradeço a Fundação de Amparo à Pesquisa do Estado de São Paulo- FAPESP pela bolsa de iniciação científica concedida.

#### **REFERÊNCIAS**

ABREU, D.; MORAES, L. A.; NASCIMENTO, E. N.; OLIVEIRA, R. A. **Impacto social da mecanização da colheita de cana-de-açúcar**. Rev Bras Med Trab. São Paulo. Vols. 4, 5 e 6. Número Especial. Julho de 2009. Disponível em: <http://www.rbmt.org.br/details/147/pt-BR/impacto-social-da-mecanizacao-da-colheita-de-cana-de-acucar>. Acesso em: 16 de fevereiro de 2022.

ANDRADE, M. M. **Introdução à metodologia do trabalho científico: elaboração de trabalhos de graduação**. São Paulo: Atlas, 1993. Cap. 3: Técnicas de Pesquisa Bibliográfica.

BAIO, F. H. R. **Aplicação de AP no Plantio**. In: RIPOLI, M. L. C.; CASGRANDI, D. V.; IDE, B. Y. (Org.). Plantio de cana-de-açúcar: estado da arte. 2. ed. Piracicaba: T. C. C. Ripoli, 2007, v. 1, p 92-101.

BAIO, F. H. R.; MOLIN, J. P.; LEAL, A. J. F. **Avaliação comparativa da distribuição transversal de adubos sólidos aplicados em culturas anuais**. Bioscience Journal, Uberlândia, v. 28, n. 4, p. 527-536, 2012. Disponível em: <http://www.seer.ufu.br/index.php/biosciencejournal/article/view/13441> Acesso em: 27 set. 2021.



BASTOS, 2015. **Usos de drones na agricultura e pecuária**. Disponível em: <<https://revistagloborural.globo.com/Noticias/Pesquisa-e-Tecnologia/noticia/2015/05/15-usos-de-drones-na-agricultura-e-na-pecuaria.html>> Acesso em: 2022-03-30.

BERNARDI, A. C. C.; NAIME, J. M.; DE RESENDE, A. V.; BASSOI, L. H.; INAMASU, R. Y. **Agricultura de Precisão: resultados de um novo olhar**. 1ª ed. Brasília – DF: EMBRAPA, 2014.

BRASIL. Ministério da agricultura pecuária e abastecimento. Portaria N 852 - Art. 1º criar a comissão brasileira de agricultura e precisão - CBAP. Diário Oficial da República Federativa do Brasil, Brasília, DF, 21 set de 2012. Sessão 1, n.184. Disponível em: <[http://www.cnpt.embrapa.br/biblio/do/p\\_do42.htm](http://www.cnpt.embrapa.br/biblio/do/p_do42.htm)> Acesso em 20 abr. 2022.

BONGIOVANNI, R.; LOWENBERG-DEBOER, J. **Precision agriculture and sustainability**. Precision Agriculture, Berlin, v.5. n.4, p. 359-387, 2004. Adoção da agricultura de precisão no rio grande do sul – Porto Alegre, RS – UFRS, 2012. Adriano Adelcino Anselmi

CARNEIRO, F. M. **Aplicação mecanizada de N-P-K individualizada na cultura da cana-de-açúcar**. 2015. vii, 86 p. Dissertação (mestrado) - Universidade Estadual Paulista Júlio de Mesquita Filho, Faculdade de Ciências Agrárias e Veterinárias de Jaboticabal, 2015.

CARVALHO, G. R. ; OLIVEIRA, C. O setor sucroalcooleiro em perspectiva. **Circular Técnica**, Campinas, V. 1, n. 1, p. 1-18, 2006.

CIRANI, C. B.; MORAIS, M. A. F. D. ; **Inovação na indústria sucroalcooleira paulista**: os determinantes da adoção das tecnologias de agricultura de precisão. RESR, Piracicaba, SP, vol. 48, Nº 4, p. 543-565, out/dez 2010 – Impressa em Março 2011.

CONAB, Companhia Nacional de Abastecimento. **Acomp. safra bras. cana**, v. 7 - Safra 2020/21, n. 4 - Quarto levantamento, Brasília, p. 1-57 maio de 2021.

DUARTE JÚNIOR, J. B.; GARCIA, R. F.; COELHO, F. C.; AMIM, R. T. **Desempenho de trator-implemento na cana-de-açúcar em sistemas de plantio direto e convencional**. Revista Brasileira de Engenharia Agrícola e Ambiental, Campina 78 Grande, v. 12, n. 6, p.653-658, 2008.

Disponível em: <<https://doi.org/10.1590/S1415-43662008000600013>>. Acesso em: 2022-03-29.

Embrapa, EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. **Agricultura de Precisão em cana-de-açúcar**. Brasília, 2014.

ESPIRITO SANTO, A. **Delineamentos de Metodologia Científica**. São Paulo: Edições Loyola, 1992. 176 p.

FERNANDES, Jeferson Lobato et al. **Monitoramento da cultura de cana-de-açúcar no Estado de São Paulo por meio de imagens SPOT Vegetation e dados meteorológicos**. 2009.

GOMES, 2018. **Drones na agricultura: tudo sobre a tecnologia que está mudando o setor**. Disponível em: <<https://www.pixforce.com.br/post/drones-na-agricultura-tudo-sobre-a-tecnologia-que-est%C3%A1-mudando-o-setor>>. Acesso em: 2022-03-30.

GREGO, C. R.; ARAUJO, L. S.; VICENTE, L. E.; NOGUEIRA, S. F.; MARGALHÃES, P. S. G.; VICENTE, A. K.; BRANCALIÃO, S. R.; VICTORIA, D. C.; BOLFE, E. L. Agricultura de precisão em cana-de-açúcar. 1ª ed. Brasília – DF: EMBRAPA, 2014.

JANINI, D. A. **Análise operacional e econômica do sistema de plantio mecanizado de cana-de-açúcar (Saccharum spp.)**. 2007. Dissertação (Mestrado em Máquinas Agrícolas) - Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 2007. doi:10.11606/D.11.2007.tde-30102007-113443. Acesso em: 12 fev. 2022.

- LEDA, V. C.; GOLÇALVES, A. K.;LIMA, N. S. **Sensoriamento remoto aplicado a modelagem de produtividade da cultura da cana-de-açúcar.** Energia na Agricultura, Botucatu, v. 34, n. 2, p.263-270, abril - junho, 2019.
- LUCHETTI, A. **Utilização de drones na agricultura:** Impactos no setor sucroalcooleiro. Palhoça, 2019.
- MOLIN, J. P.; AMARAL, L. R.; COLAÇO, A. F. **Agricultura de precisão.** 1. ed. - São Paulo: Oficina de Texto, 2015.
- MOLIN, J. P.; FRASSON, F. R.; AMARAL, L. R.; POVH, F. P.; SALVI, J. V. **Capacidade de um sensor ótico em quantificar a resposta da cana-de-açúcar a doses de nitrogênio.** Revista Brasileira de Engenharia Agrícola e Ambiental, Campina Grande, v.14, n.12, p.1345–1349, 2010.
- MOTOMIYA, A. V. de A.; MOTOMIYA, W. R.; MOLIN, J. P.; LIRA, A.; OLIVEIRA, J. R. G. Di; BISCARO, G. A. **Variabilidade espacial de atributos químicos do solo e produtividade do algodoeiro.** Revista Agrarian, Dourados, v.4, n.11, p.1-9, 2011.
- MUELLER, T.G., HARTSOCK, N.J., STOMBAUGH, T.S., SHEARER, S.A., CORNELIUS, P.L., BARNHISEL, R.I., 2003. **Soil electrical conductivity map variability in limestone soils overlain by loess.** Agronomy Journal 96, 496– 507.
- OLIVEIRA, T. Tecnologia e custos de produção de cana-de-açúcar: um estudo de caso em uma propriedade agrícola. **Latin American Journal of businessmanagement** , v. 3, n. 1, p. 150-172, 2012.
- OMEGA AGROSCIENCE, 2016. **Agricultura de Precisão: ferramentas, benefícios e vantagens.** Disponível em: <<http://www.omegaagro.com.br/2016/06/02/agricultura-de-precisaoferramentas-beneficios-e-vantagens/>>. Acesso em 2022-03-29.
- ROQUE, A. A. O.; SOUZA, Z. M.; BARBOSA, R. S.; SOUZA, G. S. **Controle de tráfego agrícola e atributos do solo em área cultivada com cana-de-açúcar.** Pesquisa Agropecuária Brasileira, Brasília, v.45, n.7, p.744-750, 2010.
- SANCHES, G. M.; SILVEIRA, H.I.; NAKAMURA, K. S.; MAGALHÃES, P. S. G. **Sensores de macronutrientes do solo “on-the-go” para fins de agricultura de precisão em cana-de-açúcar.** XL Congresso Brasileiro de Engenharia Agrícola – CONBEA 2011. julho de 2011 – Cuiabá-MT, Brasil.
- Cana-de-Açúcar. **Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA).** Disponível em:<[https://www.agencia.cnptia.embrapa.br/gestor/cana-de-acucar/arvore/CONTAG01\\_20\\_711200516716.html](https://www.agencia.cnptia.embrapa.br/gestor/cana-de-acucar/arvore/CONTAG01_20_711200516716.html)> Acesso em: 09 set. 2021.
- SCHIAVINATTO, Wilton **Análise das ações de sustentabilidade de agroindústrias paulistas citrícolas e sucroalcooleiras.** Universidade Estadual Paulista (Unesp), 2020. Disponível em: <<http://hdl.handle.net/11449/214801>>. Acesso em: 2022-03-2022.
- SCHIESSL, M. Sensores na Agricultura: 8 maneiras de deixar sua lavoura mais inteligente utilizando sensores no campo. Aegro, 2018. Disponível em: <<https://blog.aegro.com.br/sensores-na-agricultura/>> Acesso em: 28 mar. 2022
- SHIRAIISHI, Marcelo Riyudi. **Levantamento de oportunidades da aplicação das ferramentas Lean em Agricultura de Precisão: propostas dentro do setor sucroalcooleiro.** 2013. 94 f. Trabalho de Curso (Bacharelado em Engenharia de Produção) – Centro Universitário Eurípides de Marília, Fundação de Ensino “Eurípides Soares da Rocha”, Marília, 2013.
- SINDAG, 2018. **Uso de drones na agricultura brasileira.** Disponível em: <<http://sindag.org.br/uso-de-drones-na-agricultura-brasileira/>> Acesso em: 12 set. 2019.

SOUZA, Z. M.; CERRI, G. P.; COLET, M. J.; RODRIGUES, L. H. A.; MAGALHÃES, P. S. G.; MANDONI, R. J. A. **Análise dos atributos do solo e da produtividade da cultura de cana-de-açúcar com o uso da geoestatística e árvore de decisão.** Ciência Rural, Santa Maria, v.40, n.4, p.840-847, abr, 2010.

STONE, L. F.; GUIMARÃES, C. M.; MOREIRA, J. A. A. **Compactação do solo na cultura do feijoeiro. I. efeitos nas propriedades físico-hídricas do solo.** R. Bras. Eng. Agric. Amb., v. 6, n. 2, p. 207-212, 2002.

Thylén, L.; Jurschik, P.; Murphy, D.L.P. **Improving the quality of yield data I.** In: European Conference on Precision Agriculture, 1, 1997. Precision Agriculture'97, v.1, Warwick, 1997, p.743-750.

ZHANG, N.; WANG, M.; WANG, N. Precision agriculture – a worldwide overview. Computers and Electronics in Agriculture, v. 36, p. 113-132, 2002.

ZOBIOLE, L.H.S., OLIVEIRA JR., R.S.; TORMENA, C.A.; CONSTANTIN, J. ; CAVALIERI, S.D.; ALONSO, D.G.; BRIGHENTI, A.M.; CASTRO, C. **Efeito da compactação do solo e do sulfentrazone sobre a cultura da soja em duas condições de água no solo.** Planta Daninha, Viçosa-MG, v.25, n. 3, p. 537-545, 2007.

# **4. Eletrônica e transformação digital**

## CONTROLADOR DE BAIXO CUSTO PARA SEMEADURA À TAXA VARIADA

André Luiz de Freitas Coelho<sup>1</sup>; Giovani Prates Bisso Drambroz<sup>2</sup>; Daniel Marçal de Queiroz<sup>3</sup>; Domingos Sárvio Magalhães Valente<sup>4</sup>; Francisco de Assis de Carvalho Pinto<sup>3</sup>

<sup>1</sup>Engº. Mecânico, Professor - Departamento de Engenharia Agrícola, UFV, Viçosa-MG. andre.coelho@ufv.br / (31) 9 9734-9892; <sup>2</sup>Engº. Mecânico, Mestrando - Departamento de Engenharia Agrícola, UFV, Viçosa-MG;

<sup>3</sup>Engº. Agrícola, Professor - Departamento de Engenharia Agrícola, UFV, Viçosa-MG; <sup>4</sup>Engº. Agrícola e Ambiental, Professor - Departamento de Engenharia Agrícola, UFV, Viçosa-MG

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** O uso de máquinas para distribuição de insumos à taxa variada é frequente em fazendas que adotam a agricultura de precisão. Contudo, o custo de aquisição dessas máquinas é considerado alto para os agricultores de pequena escala. O objetivo do presente trabalho foi desenvolver um controlador de baixo custo para semeadura à taxa variada, com sistema de telemetria. O sistema foi desenvolvido e instalado em uma semeadora manual de uma linha com distribuidor de sementes por disco perfurado horizontal. Um motor elétrico de corrente contínua foi usado para acionar o mecanismo dosador de sementes. A velocidade angular do motor elétrico foi controlada por um programa de computador executado em um computador de placa única BeagleBone Black. Ensaios de campo foram realizados com sementes de milho, utilizando um mapa de semeadura com quatro zonas de manejo. O controlador foi eficaz na identificação das quatro zonas de manejo e no controle da velocidade angular do motor para garantir densidade de plantas estabelecida no mapa de semeadura. O sistema de telemetria foi eficaz no monitoramento remoto e em tempo real da operação de semeadura. O custo total dos componentes utilizados para desenvolver o controlador foi de US\$ 386,12, caracterizando-o como de baixo custo. Existe potencial para uso de componentes de baixo custo no desenvolvimento de controladores à taxa variada para a agricultura de pequena escala.

**PALAVRAS-CHAVE:** Agricultura de pequena escala; Sistemas embarcados; Zonas de manejo

### LOW-COST CONTROLLER FOR VARIABLE-RATE SEEDING

**ABSTRACT:** The use of machines for variable-rate applications is frequent on farms that adopt precision agriculture. However, the acquisition cost of these machines is high for smallholder farmers. The objective of this work was to develop a low-cost controller for variable-rate seeding, with telemetry system. The system was developed and installed on a one-row manual planter with a horizontal perforated disk seed meter. A direct-current electric motor was used to drive the seed metering device. The angular velocity of the electric motor was controlled by a computer program executed on a BeagleBone Black single-board computer. Field trials were performed with maize seeds, using a prescription seeding map with four management zones. The controller was effective at identifying the four management zones and controlling the angular velocity of the motor to ensure the plant density established on seeding map. The telemetry system was efficient in remote and real-time monitoring of the seeding operation. The total cost of the parts used to assemble the controller was US\$ 386.12, characterizing it as low-cost. There is potential for using low-cost components to develop variable-rate controllers for smallholder farmers.

**KEYWORDS:** Smallholder farming; Embedded system; Management zones

**INTRODUÇÃO:** A agricultura de precisão é adotada com o objetivo de aumentar a eficiência dos sistemas de produção agrícola, considerando as variabilidades espaciais e temporais da cultura e do solo. Conceitualmente, a adoção da agricultura de precisão proporciona maior lucratividade ao agricultor e menores impactos ambientais na produção de alimentos. Na operação de semeadura, a lucratividade pode ser otimizada pela adoção da densidade de plantas adequada para cada região do talhão. Locais com menor potencial produtivo recebem menor densidade de plantas, enquanto maior densidade de plantas é adotada em áreas com maior potencial de produção de alimentos (EHSANI et al., 2005). Os controladores de semeadura à taxa variada são equipamentos utilizados em semeadoras de precisão para a variação automática da densidade de

plantas a partir da variação da velocidade angular do mecanismo dosador de sementes. Diversos modelos de semeadoras com controladores de semeadura à taxa variada estão disponíveis no mercado. Também existem conjuntos de conversão que permitem transformar semeadoras de distribuição à taxa fixa em taxa variada. No entanto, o custo de aquisição dessas semeadoras ou desses conjuntos de conversão, associado à necessidade de mão-de-obra qualificada para operação e manutenção, são fatores que impedem a adoção da tecnologia por agricultores de pequena escala (BITELLA et al., 2014; MAIA et al., 2017, MAISIRI et al., 2005; VAN LOON et al., 2018). Com a recente difusão dos componentes eletrônicos de código aberto 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 (BITELLA et al., 2014; FISHER e GOLD, 2012; KAMGAR et al. 2015; LI et al. 2015; MESAS-CARRASCOSA et al., 2015). A disponibilização de controladores de aplicação à taxa variada com custo acessível, de fácil operação e manutenção, permite que os agricultores de pequena escala aumentem a eficiência do seu sistema produtivo, e conseqüentemente, os seus lucros. O objetivo do presente trabalho foi desenvolver um controlador para semeadura à taxa variada com base em mapas, com sistema de telemetria integrado para monitoramento remoto e em tempo real da operação de semeadura.

**MATERIAIS E MÉTODOS:** O controlador foi desenvolvido para ser compatível com qualquer semeadora em linha de precisão, seja de tração por trator agrícola, tração animal ou tração humana. O sistema de transmissão de potência da roda de terra para o mecanismo dosador de sementes foi removido e substituído por um motor elétrico de corrente contínua 12 V e torque nominal 9 Nm. Um controlador BTS7690 foi usado para controlar a velocidade angular desse motor a partir de um sinal modulado pela largura de pulso (PWM). Um módulo GNSS (sistema de navegação global por satélites) de baixo custo u-blox NEO-6M (u-blox AG, Suíça) foi usado para obter a geolocalização da semeadora. O módulo GSM (sistema global para comunicações móveis) SIM800L (SIM Com Wireless Solution Ltd., China) foi utilizado no sistema de telemetria do controlador, em que dados gerados durante a semeadura podem ser enviados para um servidor de armazenamento utilizando serviço de Internet disponibilizado pelas operadoras de telefonia celular. Dois discos recortados, acoplados no eixo da roda de sustentação da semeadora e no eixo do motor elétrico, e dois interruptores ópticos foram utilizados para medir a velocidade de deslocamento da semeadora e a velocidade angular real do mecanismo dosador de sementes. Um Arduino ProMini foi utilizado para ler os sinais elétricos gerados pelos interruptores óticos e calcular ambas as velocidades. Dois reguladores de tensão foram utilizados para fornecimento de energia elétrica aos componentes do controlador, com tensão 5 V e 3,7 V, a partir da energia elétrica fornecida por bateria 12 V. O computador de placa única BeagleBone Black (BBB) Revisão C (BeagleBoard.org Foundation, EUA) foi usado como unidade central de processamento do controlador de semeadura à taxa variada. A comunicação bidirecional do Arduino ProMini, módulo GSM e módulo GSM com o BBB foi implementada utilizando o protocolo de comunicação digital UART (transmissor-receptor assíncrono universal). O esquema elétrico do controlador, adaptado de Coelho (2020), é apresentado na Figura 1.

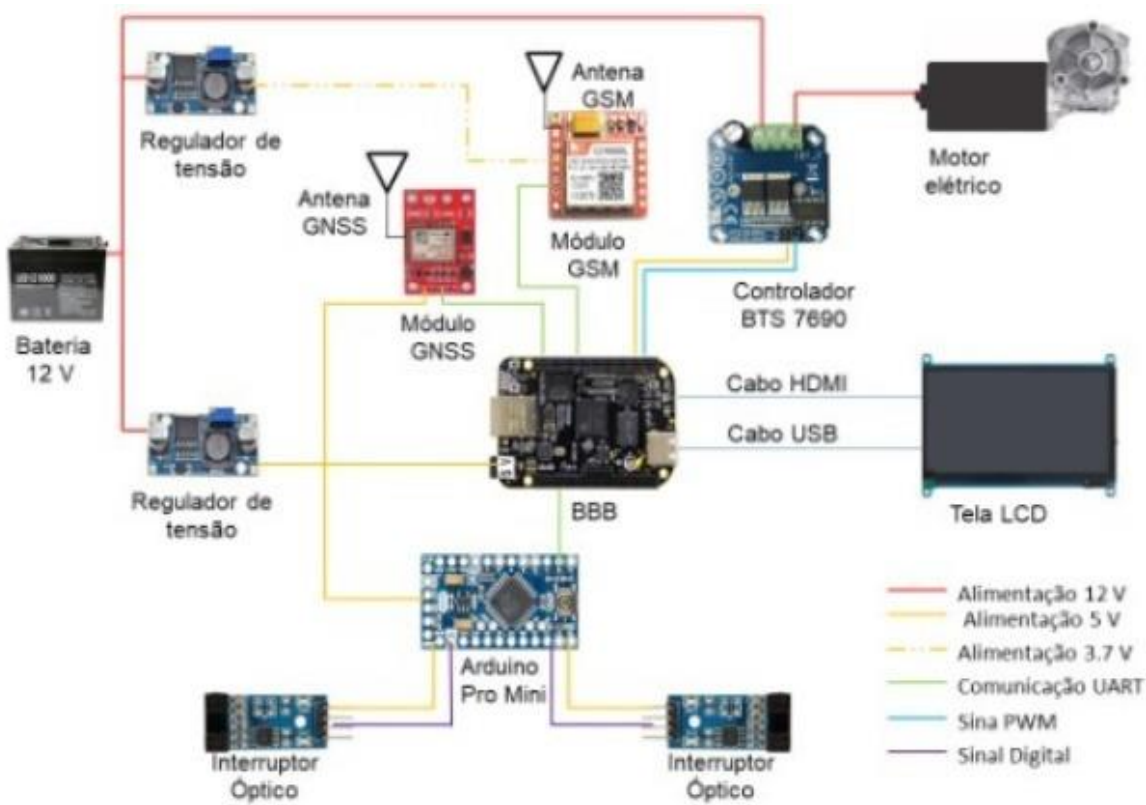


FIGURA 1. Esquema elétrico do controlador para semeadura à taxa variada com sistema de telemetria, adaptado de Coelho (2020) e Coelho et al. (2020). **Wiring diagram of the variable-rate seeding controller with telemetry system. Adapted from Coelho (2020) and Coelho et al. (2020).**

No BBB foi executado um programa de computador desenvolvido em linguagem de programação Python, versão 3.6, cujas funções são apresentadas em forma de fluxograma na Figura 2. A ferramenta PyQt5 (Riverbank Computing Limited, Reino Unido) foi usada para criar a interface gráfica do usuário para o programa de computador (telas de operação na Figura 3), sendo a interface gráfica do usuário exibida em tela LCD 800 x 640 pixels sensível ao toque conectada ao BBB.

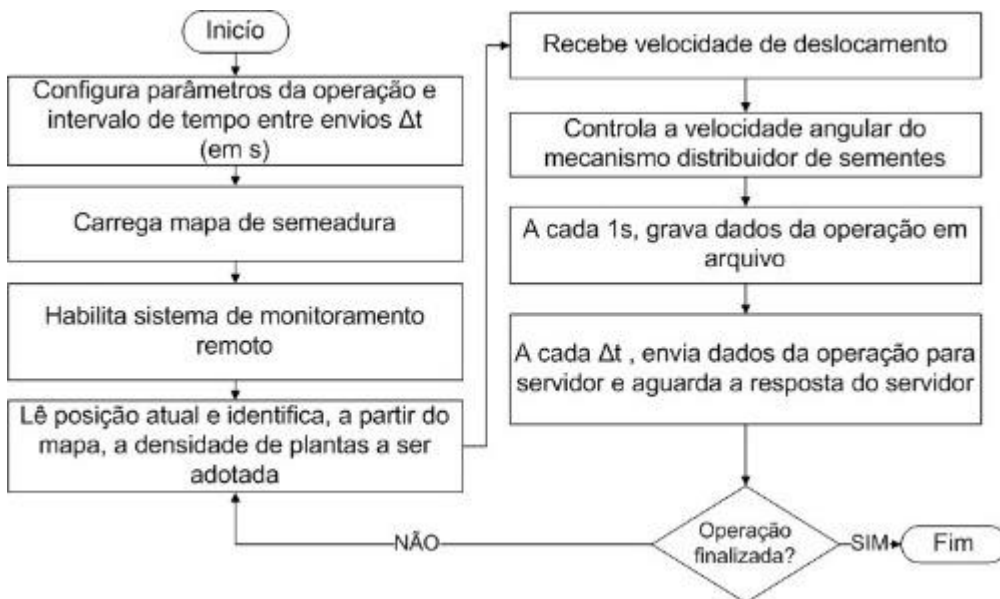


FIGURA 2. Fluxograma do programa de computador desenvolvido para o controlador de semeadura à taxa variada. Fonte: Coelho (2020). **Flowchart of the software developed for the variable-rate seeding controller. Source: Coelho (2020).**

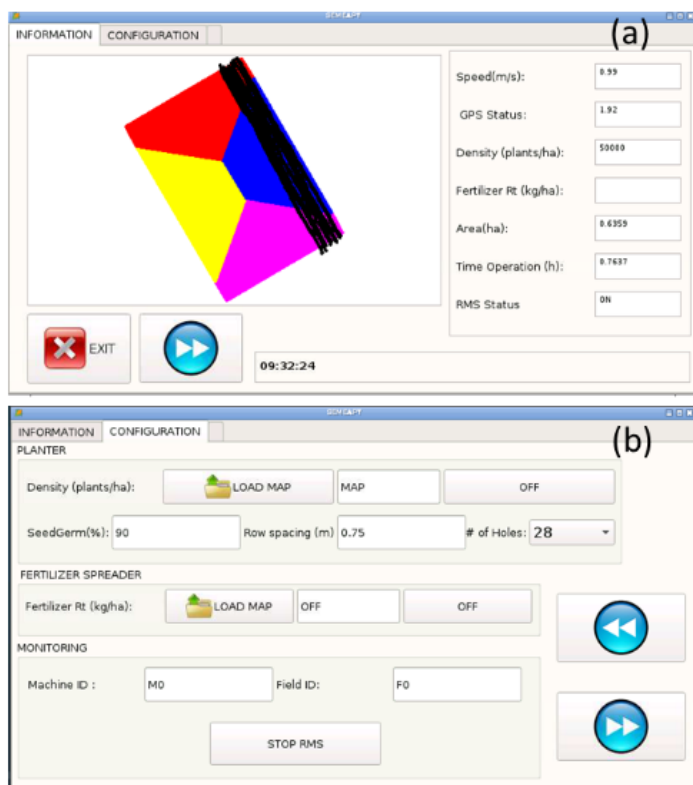


FIGURA 3. Interface gráfica do usuário do programa de computador: (a) tela de visualização de parâmetros com o mapa de semeadura e a trajetória da semeadora e (b) tela de configuração de parâmetros. Fonte: Coelho (2020). **Graphical user interface of the developed software: (a) parameter visualization tab and (b) parameter setting tab. Source: Coelho (2020).**

Dois modos de operação foram implementados no controlador: semeadura à taxa fixa e semeadura à taxa variada. No primeiro modo, o operador inseriu a densidade de plantas desejada na interface gráfica do usuário. No segundo, o usuário selecionou um arquivo de mapa, carregado em um cartão de memória e inserido no leitor de cartão do BBB. Esse arquivo, no formato *shapefile*, continha as densidades de planta para cada zona de manejo. A partir do mapa de semeadura e da localização da semeadora, obtida pelo módulo GNSS, o programa identificou a densidade de plantas prescrita para a zona de manejo na qual a semeadora estava localizada. Em ambos os modos, o programa permitiu ao operador definir o espaçamento entre linhas, o número de furos no disco perfurado horizontal e a taxa de germinação das sementes. Usando a densidade de plantas, estabelecida em um dos modos de operação, a velocidade de deslocamento da semeadora, espaçamento entre linhas, o número de furos no disco perfurado horizontal e a taxa de germinação das sementes, o programa calculou a velocidade angular do motor elétrico e enviou sinal PWM ao controlador BTS7960.

Para o monitoramento remoto e em tempo real da operação de semeadura, desenvolveu-se um sistema de telemetria integrado ao controlador. Utilizando o módulo GSM, os dados da operação foram enviados para um servidor de armazenamento utilizando serviço de Internet disponibilizado pelas operadoras de telefonia celular. Entre os dados enviados ao servidor têm-se o nome da máquina e do talhão, geolocalização da semeadora, velocidade de deslocamento da máquina, tempo de operação para o talhão, área semeada, capacidade operacional média, a densidade de plantas adotada na semeadura e a velocidade angular do motor de acionamento mecanismo dosador de sementes. Para armazenamento dos dados utilizou-se um banco de dados com tecnologia SQL (*Structured Query Language*). Para visualização dos dados pelo gestor, um aplicativo para dispositivos móveis com sistema operacional Android foi desenvolvido utilizando a plataforma *MIT App Inventor*.



O controlador de semeadura à taxa variada com sistema de telemetria foi instalado em uma semeadora de precisão com uma linha de semeadura e tração humana. A área utilizada no ensaio da semeadora continha solo argiloso e topografia plana, em formato de retângulo com dimensão 90 × 60 m. Adotou-se semeadura convencional, sendo o preparo do solo realizado por gradagem em duas passadas. Um mapa de semeadura foi criado dividindo a área retangular em quatro zonas de manejo, atribuindo as densidades de 40000, 50000, 60000 e 70000 plantas ha<sup>-1</sup>. A organização das zonas de manejo foi definida de forma a produzir duas alterações na densidade de plantas em cada linha de semeadura. Utilizou-se o programa de computador de código aberto QGIS versão 2.18 (QGIS Development Team, 2009) para geração do mapa de semeadura, sendo o mapa salvo em formato de arquivo *shapefile* e inserido na memória do controlador. Foram utilizadas sementes de milho da cultivar CRV 3042, com taxa de germinação 97% e vigor 93% determinados em laboratório, usando os procedimentos recomendados pela Regra de Análise de Sementes (MAPA, 2009). A semeadura foi realizada adotando profundidade 5,0 cm, utilizando um disco perfurado com 28 orifícios oblongos 14,0 x 9,5 mm. O espaçamento entre linhas configurado no programa de computador do controlador foi 0,75 m, e controlado de forma manual pelo operador. A velocidade de deslocamento da semeadora foi mantida próxima a 1 m s<sup>-1</sup>. Os dados gerados durante a operação de semeadura foram registrados na memória do controlador a cada 1 s, e enviados para o servidor de armazenamento a cada 4 s.

Para avaliar o desempenho da semeadora com o controlador, determinou-se a densidade real de plantas em cada zona de manejo. O experimento foi planejado adotando delineamento inteiramente casualizado com quatro tratamentos, correspondentes às zonas de manejo, e com 10 repetições cada, resultando em 40 parcelas experimentais. Em cada parcela, escolhida aleatoriamente dentro da zona de manejo, o número de plantas em uma área 3,0 m × 3,0 m foi determinado e convertido para número de plantas em um hectare. Para avaliar o desempenho do sistema de telemetria, comparou-se o número de dados salvos na memória da BBB e no servidor de armazenamento.

**RESULTADOS E DISCUSSÃO:** O programa de computador desenvolvido para o controlador de semeadura à taxa variada foi nomeado como *SemeaPy*, e registrado no Instituto Nacional da Propriedade Industrial (INPI) sob o número BR512019002803-1. O programa de computador em linguagem PHP desenvolvido para ser executado no servidor de armazenamento e o aplicativo de visualização dos dados foram nomeados como *SemeaView* e registrados no INPI sob número BR512019002804-0. A fim de torna-los público e livre para uso e modificação, os códigos-fonte dos programas de computador desenvolvidos foram disponibilizados em <https://github.com/LabDig/SemeaPy5> e <https://github.com/LabDig/SemeaView>. O custo com aquisição dos componentes para a fabricação do controlador foi de US\$ 386,12 (Tabela 1), o que permite caracterizar o produto desenvolvido como 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 GOULD, 2012). Outra vantagem dos componentes de projeto aberto comparado aos componentes de tecnologia proprietária é a maior flexibilidade na escolha dos componentes a serem utilizados, visto que não há menor incompatibilidade entre componentes que estão sendo usados (MESAS-CARRASCOSA et al., 2015).

TABELA 1. Custo de aquisição dos componentes utilizados no controlador de semeadura à taxa variada com sistema de telemetria. Fonte: Adaptado de Coelho et al. (2020). **Acquisition cost of components used in the variable-rate seeding controller with telemetry system. Source: Adapted from Coelho et al. (2020).**

Qtde.	Componente	Especificações	Fabricante	Custo Unitário (US\$) *
1	BeagleBone Black Revisão C	Processador Sitara AM3358 ARM Cortex-A8 1,0 GHz. 512 MB RAM e 96 pinos de uso geral	BeagleBoard.org Foundation, EUA	94,95
1	Tela LCD	Entrada HDMI, resolução 800 × 600 pixels, sensível ao toque	Waveshare Electronics, China	79,99
1	Controlador para motor BTS7960	Tensão de entrada 12 a 24 V, corrente elétrica máxima 43 A e tensão do sinal lógico 3,3 a 5 V	HiLetgo Technology Co, China	15,99

1	Motor elétrico	Tensão de entrada 12 V, velocidade angular máxima 5.2 rad s <sup>-1</sup> e torque nominal 9 Nm	Makermotor, EUA	76,00
2	Interruptor óptico	Tensão de entrada 3,3 a 5 V	Vishay Semiconductors, EUA	1,90
1	Arduino ProMini	Tensão de entrada 3,3 V e frequência de operação 8 MHz	SparkFun Electronics, EUA	8,33
1	Módulo GNSS NEO-6M com antena de base magnética	Frequência de recepção de dados 1 Hz e tensão de entrada 3,3 a 5 V. Antena com ganho 28 dBi	u-blox AG, Suíça	19,98
1	Bateria recarregável	Tensão 12 V e capacidade 18 Ah	Powerstar, Reino Unido	38,99
1	Módulo GSM SIM800L com antena de base magnética	Frequências de operação: 850, 900, 1800 e 1900 MHz. Tensão de operação: 3,6 a 4,2 V. Antena com ganho 28 dBi.	SIM Com Wireless Solution, China	19,99
1	Caixa para montagem, regulador de tensão, cabos elétricos e conectores			30,00
<b>Custo total (US\$)</b>				<b>386,12</b>

\* Preços obtidos em lojas virtuais, em abril de 2022.

Observou-se diferença significativa, ao nível de 5% pelo teste de Tukey, nas densidades reais de plantas nas quatro zonas de manejo (Tabela 2). Esses resultados mostraram que o controlador desenvolvido foi eficaz em identificar a zona de manejo em que a semeadora estava localizada, ler no mapa a densidade de plantas, e a partir da velocidade de deslocamento e outras variáveis, calcular e controlar a velocidade angular do motor elétrico. Durante a operação de semeadura, o controlador permaneceu em operação por 3,53 h, resultando no armazenamento de 12816 dados na memória interna do BBB. Utilizando o sistema de monitoramento remoto, os dados foram enviados ao servidor a cada 4 s, constatando-se sucesso no envio e armazenamento de 3075 dados (95,9%). A quantidade de falhas de envio (4,1%) foi considerada aceitável, visto que não impossibilitaram a geração dos mapas de operação. O sistema de telemetria, utilizando o módulo GSM para envio de dados utilizando redes de telefonia celular, possibilitou ao gestor da fazenda monitorar, de forma remota e em tempo real, a operação de semeadura (Figura 4).

TABELA 2. Comparação entre as densidades de plantio reais e prescritas nas quatro zonas de manejo. Fonte: Coelho et al. (2020). **Comparison between actual and prescribed planting densities in the four management zones. Source: Coelho et al. (2020).**

Densidade de plantas prescrita no mapa (plantas ha <sup>-1</sup> )	Densidade de planta real (plantas ha <sup>-1</sup> )	
	Média*	Desvio-padrão
40000	44333 a	2694
50000	48222 b	5398
60000	62889 c	3403
70000	71333 d	3948

\* As médias seguidas de letras diferentes dentro de uma coluna são significativamente diferentes a 5% pelo teste de Tukey.




FIGURA 4. Tela do aplicativo *SemeaView* apresentando o mapa de velocidade de deslocamento da semeadora. **SemeaView app screen showing the planter speed map.**

O baixo custo e o desempenho satisfatório do controlador na variação da densidade de plantas conforme o mapa de semeadura, além do desempenho satisfatório do sistema de telemetria, mostram que o controlador de semeadura à taxa variada desenvolvido no presente trabalho, utilizando componentes de projeto aberto e programas de computador e linguagem de programação de código aberto e gratuitos, tem potencial para ser utilizado por agricultores de pequena escala. Além de semeadoras manuais com uma linha, como a utilizada no presente trabalho, o controlador desenvolvido pode ser utilizado em qualquer semeadora, inclusive aquelas tracionadas por trator. Caso a semeadora contenha duas ou mais linhas de semeadura e o agricultor.

**CONCLUSÃO:** O controlador desenvolvido utilizando componentes de projeto aberto teve custo de US\$ 386,12, permitindo caracterizá-lo como de baixo custo. Em uma operação de semeadura, o controlador foi eficaz no controle da velocidade angular do motor elétrico, utilizando dados da densidade de plantas prescrita no mapa de semeadura, velocidade de deslocamento da semeadora e os dados inseridos pelo operador. O sistema de telemetria foi eficaz no envio e armazenamento de dados no servidor, permitindo o monitoramento remoto e em tempo real da operação de semeadura.

#### **AGRADECIMENTOS:**

Ao Conselho Nacional de Pesquisa e Desenvolvimento (CNPq), Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES – código de Financiamento 001) pelo apoio financeiro.

#### **REFERÊNCIAS**

BITELLA, G.; ROSSI, R.; BOCHICCHIO, R.; PERNIOLA, M.; AMATO, M. A novel low-cost open-hardware platform for monitoring soil water content and multiple soil-air-vegetation parameters. *Sensors*, v.14, n.10, p. 19639–19659, 2014.

COELHO, A.L.F.; QUEIROZ, D.M.; VALENTE, D.S.M.; PINTO, F.A.C. Development of a variable-rate controller for a low-cost precision planter. **Applied Engineering in Agriculture**. v.36, n.2, p.233–243, 2020.

COELHO, A.L.F. **Desenvolvimento de um sistema de aplicação à taxa variada para produção em pequena escala**. 2020. 80f. Tese (Doutorado em Engenharia Agrícola) - Universidade Federal de Viçosa, Viçosa, 2020.

EHSANI, M.R.; DURAIRAJ, C.; WOODS, S.C.; SULLIVAN, M. Potential Application of Electrical Conductivity (EC) Map for Variable Rate Seeding. **Agricultural Engineering International: the CIGR journal**. Manuscript IT 05 006. v.7, 2005.

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.

KAMGAR, S.; NOEI-KHODABADI, F.; SHAFAEI, S.M. Design, development, and field assessment of a controlled seed metering unit to be used in grain drills for direct seeding of wheat. **Information Processing in Agriculture**, v.2, n.3–4, p.169–176. 2015.

LI, Y.; HE, X.T.; TAO, C.; ZHANG, D.X.; SONG, S.; RUI, Z.; MANTAO, W. Development of mechatronic driving system for seed meters equipped on conventional precision maize planter. **International Journal of Agricultural and Biological Engineering**, v.8, n.4, p.1–9, 2015.

MAIA, R.F.; NETTO, I.; TRAN, A. L. H. Precision agriculture using remote monitoring systems in Brazil, **2017 IEEE Global Humanitarian Technology Conference (GHTC)**, San Jose, CA, 2017, p.1-6.

MAISIRI, N.; SENZANJE, A.; ROCKSTROM, J.; TWOMLOW, S.J. On farm evaluation of the effect of low-cost drip irrigation on water and crop productivity compared to conventional surface irrigation system. **Physics and Chemistry of the Earth**, v.30, n.11-16, p.783–791, 2005.

MAPA - MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO. **Regra de Análises de Sementes**. Brasília. 2009.

MESAS-CARRASCOSA F.J.; VERDÚ SANTANO, D.; MEROÑO, J.E.; SÁNCHEZ, M.; GARCÍA-FERRER, A. Open source hardware to monitor environmental parameters in precision agriculture. **Biosystems Engineering**, n.137, p.73-83, 2015.

VAN LOON, J.; SPERATTI, A.B.; GOVAERTS, B. Precision for smallholder Farmers: A Small-Scale-Tailored Variable Rate Fertilizer Application Kit. **Agriculture**, v.8, n.4, p.1-14, 2018.

# Análise de uma Arquitetura em Nuvem da AWS para Telemetria em Máquinas Agrícolas

**SANDRO MOTTER<sup>1</sup>; ALEXANDRE LAZARETTI ZANATTA<sup>2</sup>; GUILHERME SILVA DE OLIVEIRA<sup>3</sup>; ANDREI BECKER PACHECO<sup>4</sup>; EDINEI FIORESE<sup>5</sup>**

<sup>1</sup>Eng. de Computação, Graduando - Universidade de Passo Fundo, Campus Av. Brasil Leste, 285 - São José, Passo Fundo - RS, 99052-900, Universidade de Passo Fundo, Campus Av. Brasil Leste, 285 - São José, Passo Fundo - RS, 99052-900. sandromotter@gmail.com / (54) 9 9992-6055; <sup>2</sup>Doutor em Ciência da Computação, Professor - Universidade de Passo Fundo, Campus Av. Brasil Leste, 285 - São José, Passo Fundo - RS, 99052-900, Universidade de Passo Fundo, Campus Av. Brasil Leste, 285 - São José, Passo Fundo - RS, 99052-900; <sup>3</sup>Eng<sup>o</sup> Eletricista Esp. em Agricultura de Precisão e Gestão de Projetos, Supervisor de Engenharia de Produto - Stara S/A Ind. Impl. Agr., Não-Me-Toque/RS, Stara S/A Ind. Impl. Agr., Não-Me-Toque/RS; <sup>4</sup>Analista de Sistemas, Projetista de Software de Produto - Stara S/A Ind. Impl. Agr., Não-Me-Toque/RS, Stara S/A Ind. Impl. Agr., Não-Me-Toque/RS; <sup>5</sup>Analista e Desenvolvedor de Sistemas, Projetista de Software de Produto - Stara S/A Ind. Impl. Agr., Não-Me-Toque/RS, Stara S/A Ind. Impl. Agr., Não-Me-Toque/RS

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Gerar conhecimento a partir da análise de dados advindos de máquinas agrícolas, é uma forma de auxiliar o produtor no processo que pode aumentar sua produtividade e rentabilidade. Este trabalho analisou uma arquitetura baseada na computação em nuvem para telemetria em máquinas agrícolas. Para isso, foram analisadas várias plataformas comerciais que oferecem serviços na nuvem, após desenvolveu-se uma solução envolvendo hardware, software e serviços na nuvem para coleta e envio de dados como velocidade, latitude e longitude. Realizou-se um estudo de campo para analisar a viabilidade da arquitetura. Os resultados indicam que a solução atendeu os objetivos propostos.

**PALAVRAS-CHAVE:** Arquitetura AWS; Telemetria em Máquinas Agrícolas; -

## ANALYSIS OF AN AWS CLOUD ARCHITECTURE FOR AGRICULTURAL MACHINE TELEMETRY

**ABSTRACT:** Generating knowledge from the analysis of data from agricultural machinery is a way of helping the producer in the process that can increase his productivity and profitability. This work analyzed an architecture based on cloud computing for telemetry in agricultural machines. For this, several commercial platforms that offer services in the cloud were analyzed, after which a solution was developed involving hardware, software and services in the cloud to collect and send data such as speed, latitude and longitude. A field study was carried out to analyze the feasibility of the architecture. The results indicate that the solution met the proposed objectives.

**KEYWORDS:** AWS Architecture; Telemetry in Agricultural Machines; -

**INTRODUÇÃO:** Máquinas agrícolas podem ser consideradas coletoras de dados, sendo capazes de obter informações de solo, clima e produtividade, o que, por consequência, torna de grande importância a obtenção de meios para transmitir essas informações da máquina ao agricultor. Segundo (THOMPSON, DELAY & MINTERT, 2021), resultados indicam que a maioria das fazendas de soja e milho dos EUA coletam dados, que influenciam diretamente na tomada de decisão do agricultor e as fazendas que ainda não investiram em gerenciamento e recursos de análise de dados podem estar perdendo possíveis benefícios associados ao uso desses em suas fazendas para melhorar a tomada de decisão da propriedade.

A evolução dos dispositivos de IoT (Internet das Coisas), que auxiliam na coleta de dados, por exemplo, trouxe inovação para vários setores industriais, e essa vem sendo aplicada nos campos de transporte, saúde, veículos e casas inteligentes (AL-FUQAHA et al, 2015 apud SRIVASTAVA & DAS, 2021). No ramo agrícola o

cenário não é diferente, telemetria é uma das aplicações utilizadas na agricultura, auxiliando na captura e monitoramento de dados de máquinas agrícolas. Esta tecnologia contribui na tomada de decisão, aumentando a produtividade no campo economizando insumos, tempo e dinheiro, ao mesmo tempo que contribui com o gerenciamento e logística das máquinas (SRIVASTAVA & DAS, 2021).

Um dos problemas enfrentados por empresas que disponibilizam serviços de telemetria, no que se refere a milhares de máquinas conectadas simultaneamente enviando dados em tempo real, é a complexidade da arquitetura de nuvem, onde, geralmente ao invés da equipe de desenvolvimento de software, colocar esforços em desenvolver novas funcionalidades, necessita investir tempo em manter os servidores ativos, desenvolver a parte de segurança da informação e além de dar manutenção aos mesmos. Normalmente esses modelos são feitos apenas com um serviço, por isso, esse trabalho tem como objetivo principal analisar uma estrutura modular em nuvem da AWS (Amazon Web Services), uma plataforma de computação em nuvem oferecida pela Amazon.com, para telemetria em máquinas agrícolas, onde cada módulo é representado por um serviço de nuvem. Para o estudo de caso, e apenas para fins de análise do comportamento desta estrutura, os dados de velocidade, latitude e longitude foram eleitos para a coleta.

**MATERIAIS E MÉTODOS:** Esta seção apresenta os materiais e métodos utilizados no trabalho. Inicialmente realizou-se um estudo sobre as plataformas de computação em nuvem disponíveis no mercado, incluindo a Google Cloud Platforms e a Microsoft Azure, onde foi optado pelo uso da Amazon Web Services (AWS) por conta dos serviços de IoT (internet das coisas) disponibilizados, treinamentos e casos de usos com empresas no ramo agrícola. Em seguida, para coletar e enviar dados de velocidade, latitude e longitude à nuvem, realizou-se uma pesquisa de microcontroladores, incluindo o STM32f103 e o TM4C1232H6PM, onde definiu-se o uso do ESP32 juntamente com o framework oficial da Espressif (ESP-IDF), e a placa de desenvolvimento ESP32-DevKitC por possuir tecnologia com Wifi integrada, dispor biblioteca de comunicação com serviços IoT da AWS, devido ao uso do sistema operacional FreeRTOS, e ser qualificada pela Amazon Web Services (ESPRESSIF SYSTEMS, 2021).

Posteriormente, utilizou-se o Framework React Native, uso do pacote react-native-maps, para desenvolver o aplicativo, principalmente, devido a AWS dispor de ferramentas para conexão com os serviços de banco de dados. Na figura 1, pode-se observar os passos metodológicos do presente trabalho.

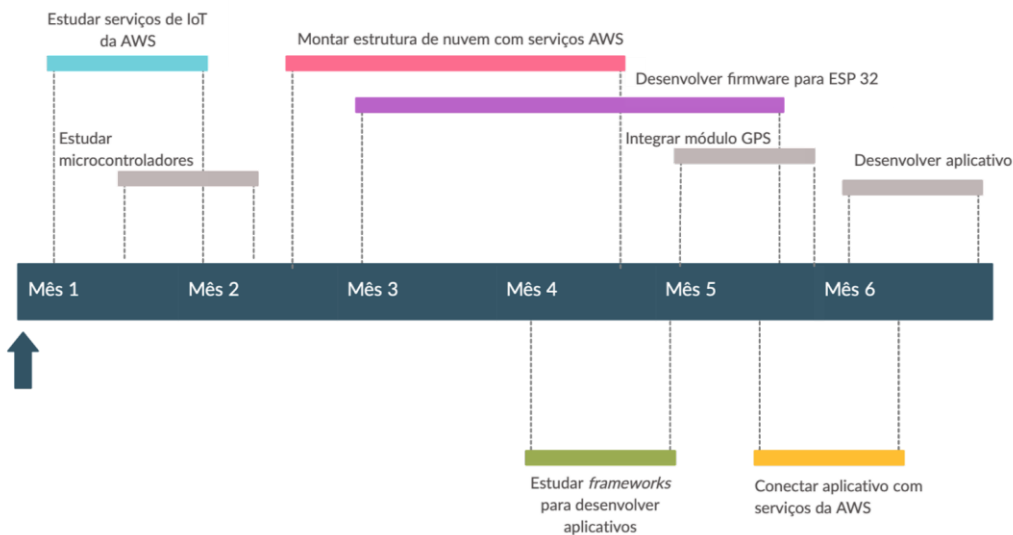


Figura 1. Passos metodológicos

Fonte: Elaboração própria

O hardware proposto tem como objetivo coletar os dados de velocidade, latitude e longitude, e transmiti-los via internet com conexão wifi, através do protocolo MQTT para os serviços da AWS, em tempo real. O MQTT (do inglês Message Queue Telemetry Transport) é um protocolo de mensagens padrão OASIS (Organização para o Avanço de Padrões em Informação Estruturada) para IoT, com transporte de mensagens de publicação

/ assinatura contendo um cabeçalho fixo de 2 bytes. O hardware deve ser capaz de receber e executar comandos enviados pela nuvem.

Utilizou-se um microcontrolador da série ESP32, fabricado pela empresa TSMC (Taiwan Semiconductor Manufacturing Company) e criado e desenvolvido pela Espressif Systems. A placa de desenvolvimento utilizada foi a ESP32-DevKitC, no qual fornece tecnologia Wifi e Bluetooth integrada. O mesmo utiliza um micro processador Tensilica Xtensa LX6, tendo uma operação de até 240 MHz e dispondo de 4 MB de memória flash. A configuração dos pinos apresenta 39 de entrada e saída, sendo todas elas configuráveis para PWM; também dispõe de comunicação UART, i2c, SPI, possui 2 canais DAC e 16 pinos ADC com resolução de 12 bit, operando a uma faixa de 0 a 3,3 Volts (COMPONENTS 101, 2020).

Empregou-se o FreeRTOS, sistema operacional (SO) em tempo real para microprocessadores e microcontroladores. Este SO é distribuído gratuitamente sob a licença do MIT (AMAZON WEB SERVICES, INC. OR ITS AFFILIATES, 2021c). Ele fornece conectividade pronta para o uso de serviços IoT da AWS, por isso com o auxílio da estrutura de desenvolvimento IoT da Espressif, a esp-idf, o SO foi utilizado na placa de desenvolvimento ESP32-DevKitC, no quais são placas qualificadas pela AWS (ESPRESSIF SYSTEMS, 2021).

A captura em tempo real da localização e velocidade das máquinas realizou-se através do módulo GPS NEO-6M-0-001, fornecido pela empresa U-blox. O mesmo se comunica com o microcontrolador por meio do protocolo UART, onde pode apresentar uma precisão da posição (latitude e longitude) de até 2,5 metros (U-BLOX AG, 2011). Para o firmware desenvolvido para o microcontrolador utilizou-se a linguagem C com as bibliotecas da AWS para a comunicação com protocolo MQTT, com o auxílio de um parser fornecido pela Espressif para decodificar os dados obtidos do módulo GPS. Para energizar os componentes de hardware, utilizou-se um powerbank de marca e fabricantes desconhecidos. Essa estrutura foi fixada em uma base de madeira. Uma parte do hardware pode ser visto na figura 2.



Figura 2. Hardware projetado

Fonte: Elaboração própria

O protocolo MQTT é usado em uma ampla variedade de indústrias, manufatura, telecomunicações, petróleo e gás.(MQTT, 2020). Na indústria automobilística não é diferente, segundo (HIVEMQ GMBH, 2021), a BMW, fabricante de carros, utiliza o protocolo MQTT.

Neste protocolo, os “tópicos” são canais que permitem elementos se comunicarem entre si, portanto, o elemento que deseja receber informações deve se inscrever em um tópico, fazendo uma requisição ao Broker que irá publicar os dados, nos quais foram recebidos do dispositivo que os está publicando no mesmo tópico, logo o Broker é o elemento da rede que intermedia o processo de comunicação.

Pode-se observar o funcionamento da estrutura de tópicos do protocolo MQTT na figura 3, no qual há o AWS IoT Core MQTT Broker para processar mensagens, o Device que é o dispositivo a ser controlado a Application que é a aplicação que envia comandos e recebe dados remotamente. A figura 3 apresenta um exemplo do funcionamento da estrutura de tópicos do protocolo MQTT (IOT ATLAS, 2021):

- Após o Device se conectar com o AWS Iot Core, ele se inscreve no tópico "cmd/device1/req", no qual é o que irá receber mensagens.
- A Application se inscreve no tópico "cmd/device1/resp" após se conectar com o AWS IoT Core, onde será recebido as mensagens do Device.
- A Application publica uma mensagem no tópico "cmd/device1/req" para enviar um comando para o Device tomar uma ação.
- Este passo é opcional. Depois que o comando foi processado, o Device publica o resultado da ação no tópico "cmd /device1/resp", e logo em seguida a Application recebe a mensagem de resposta e reconcilia a ação pendente.

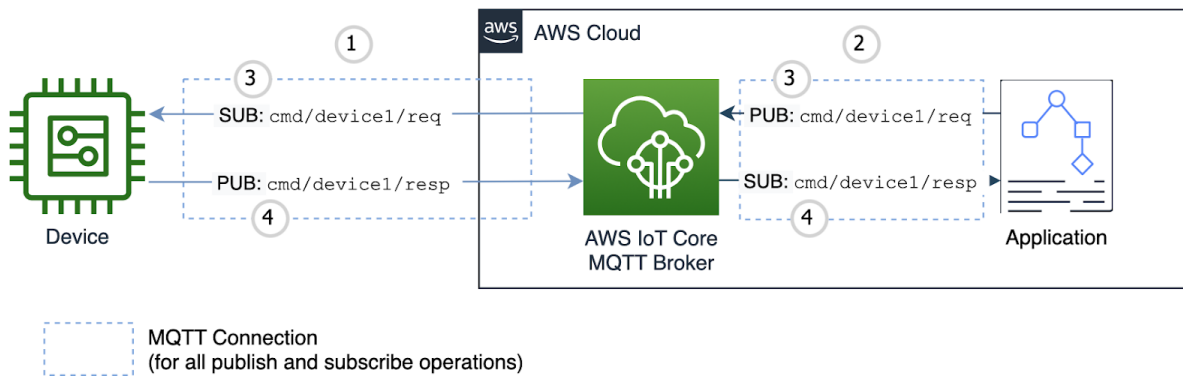


Figura 3. Tópicos MQTT

Fonte: IOT ATLAS, 2021

Em cada conexão entre dois elementos, por exemplo o device e o application, há um nível de qualidade de serviço (QoS, de Quality of Service), no qual utilizou-se o nível 0. Segundo (BARROS,2015) a conexão pode dispor de três níveis de qualidade de serviço, sendo elas:

- QoS 0 (at most once): Conhecida como best effort, onde não há confirmações de entregas das mensagens, e também a parte que envia mensagens, não há a obrigação de manter mensagens armazenadas para futuras retransmissões;
- QoS 1 (at least once): No nível um existe uma confirmação de entrega das mensagens, logo se mostra viável em situações onde o elemento que envia acaba gerando várias mensagens iguais possivelmente por um atraso na confirmação de recebimento. Portanto, neste caso, é garantido que alguma delas terá o reconhecimento realizado. Além de que neste nível existe um armazenamento da mensagem por parte de quem envia até a confirmação.
- QoS 2 (exactly once): Já neste nível, é garantido que a mensagem seja entregue exatamente uma vez, já que o mesmo dispõe de duas confirmações de recebimento, nos dois sentidos da conexão.

Todo o tráfego entre microcontrolador e AWS IoT é transmitido e criptografado pelo Transport Layer Security (TLS). Já o movimento de dados entre serviços da AWS é protegido pelos mecanismos de segurança da nuvem da AWS (AMAZON WEB SERVICES, INC. OR ITS AFFILIATES, 2021a).

Realizou-se um estudo dos serviços de IoT disponibilizados pela AWS, e em seguida, foi projetado uma arquitetura para realizar o monitoramento, em tempo real, das variáveis de velocidade, latitude e longitude das máquinas agrícolas e também o envio de dados às mesmas através de um aplicativo móvel. Projetou-se toda a estrutura para ser modular, onde cada módulo representa um serviço da AWS, no qual permite a alteração, remoção ou inserção de novos serviços conforme a necessidade individual. Os serviços da AWS utilizados



foram: AWS Iot Core, Device Shadow, AWS Lambda, Amazon DynamoDB, AppSync e AWS Amplify que serão a seguir detalhados:

O serviço AWS IoT Core, disponibiliza uma infraestrutura que permite a conexão de dispositivos de IoT à nuvem da AWS, excluindo a necessidade de provisionar e gerenciar servidores (AMAZON WEB SERVICES, INC. OR ITS AFFILIATES, 2021b). Conforme Borelli, (AMAZON WEB SERVICES, INC. OR ITS AFFILIATES, 2021b):

"Hoje temos dispositivos instalados nos tratores e caminhões dos nossos clientes para coletar informações sobre suas operações. Se eles estão preparando o solo, ou semeando, estes dados são coletados segundo a segunda e enviados para a plataforma AWS IoT. Nossos clientes usam estas informações para fazer a gestão de suas produções e tomar decisões em tempo real."

Para monitorar e enviar os dados, empregou-se o serviço da Aws IoT, Device Shadow, no qual adiciona um documento em formato JSON (Javascript Object Notation) no banco DynamoDB mantendo o estado atual de cada dispositivo conectado à nuvem (AMAZON WEB SERVICES, INC. OR ITS AFFILIATES, 2021f). O intuito de utilizá-lo é para manter uma sincronização dos dados entre máquina agrícola e aplicativo, por exemplo, caso o cliente envie comando para a máquina e ela esteja sem conexão com a internet, o comando será executado no momento em que a conexão for restabelecida.

O AWS Lambda é um serviço de computação que executa suas aplicações em um modelo serverless, onde não é preciso se preocupar com a infraestrutura da aplicação. Ele executa a manutenção do sistema operacional e do servidor, incluindo o provisionamento automático de monitoramento e registro de logs, servindo para qualquer tipo de aplicação backend (AMAZON WEB SERVICES, INC. OR ITS AFFILIATES, 2021e). O serviço é compatível com as principais linguagens de programação do mercado como: Javascript rodando com o Node.js, Python, Ruby, Java, Go e .NET Core (AMAZON WEB SERVICES, INC. OR ITS AFFILIATES, 2021e).

O Banco de dados utilizado foi o Amazon DynamoDB que possui o serviço de dois modos de capacidade de leitura/gravação para processar leituras e gravações em suas tabelas, sendo: a) provisionado e b) sob demanda. Segundo (AMAZON WEB SERVICES, INC. OR ITS AFFILIATES, 2021g), o provisionado, no qual é possível especificar o número de leituras e gravações, é recomendado pela AWS para aplicações que possuem tráfego de dados previsíveis, permitindo assim uma maior governança e previsibilidade de custos. O segundo modo é o sob demanda, onde o custo é aplicado apenas no que é utilizado, no qual é indicado pela (AMAZON WEB SERVICES, INC. OR ITS AFFILIATES, 2021g) em aplicações onde possuem tráfegos imprevisíveis e há criações de tabelas com cargas desconhecidas.

Com o auxílio do serviço AppSync, desenvolveu-se uma API (Application Programming Interface) GraphQL, para disponibilizar assinaturas para aplicações móveis e Web, e para dar suporte a atualizações em tempo real. O serviço recebe dados da máquina através de uma Lambda Function, sincroniza os mesmos com o banco DynamoDB e dispara eventos com dados atualizados a todos clientes front-end conectados à API.

Desenvolveu-se um o aplicativo para o monitoramento das máquinas agrícolas, onde dados como velocidade, latitude e longitude são mostrados em tempo real, sendo que a posição geográfica e o caminho realizado das mesmas, podem ser observadas através de um mapa com visão de satélite com o auxílio do pacote react-native-maps. Além disso, a aplicação permite o envio de comandos como “ligar” e “desligar” o motor das máquinas.

Para desenvolver esse aplicativo utilizou-se o framework React Native que possibilita o desenvolvimento de aplicações para sistemas operacionais Android e iOS, utilizando a linguagem Javascript que é renderizada para código nativo para cada sistema. Assim como, para o aplicativo se conectar com a API Graph QL da nuvem da Amazon Web Services, utilizou-se a biblioteca de javascript de código aberto, AWS Amplify para React Native, e uma chave para autenticação. Também usou-se o mesmo método de autenticação para se conectar com o API Gateway.

Pode-se observar a estrutura analisada na figura 4.

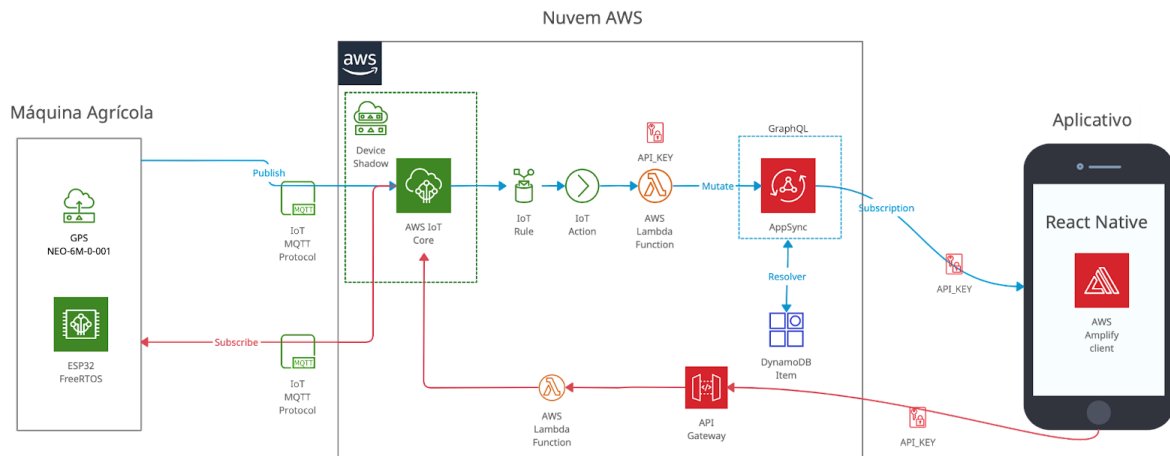
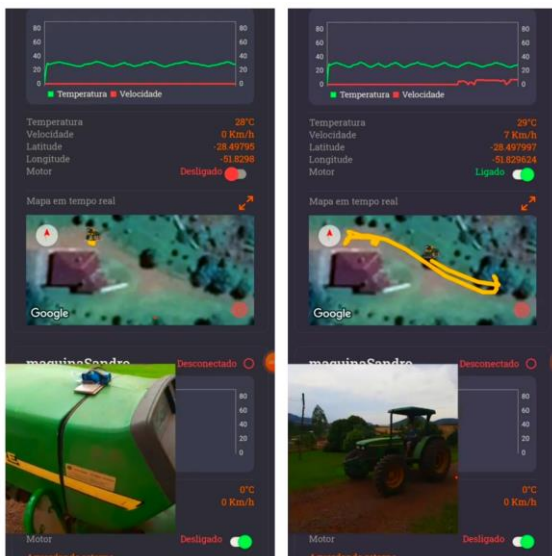


Figura 4. Estrutura do trabalho

Fonte: Elaboração própria

**RESULTADOS E DISCUSSÃO:** Esta seção, juntamente com o estudo de caso, demonstra os resultados da análise sobre a arquitetura de nuvem, sendo eles, a estrutura e o fluxo de dados dos serviços da Amazon Web Services, o hardware e o aplicativo desenvolvido.

Realizou-se um estudo de caso a campo para coletar dados e analisar a arquitetura em nuvem para telemetria em máquinas agrícolas. Como pode ser visto na figura 5 (a), o microcontrolador juntamente com o módulo GPS, foi colocado em uma máquina agrícola, e conforme o trator se locomovia as variáveis de velocidade, latitude e longitude eram coletadas a cada 100 milissegundos e transmitidas, em tempo real, e mostradas no aplicativo, como pode ser visto na figura 5 (b). Também testou-se o envio de dados do aplicativo para a máquina, onde a variável controlada foi o estado do motor, no qual foi apenas simulado.



(a) hardware na máquina agrícola (b) monitoramento das

variáveis pelo aplicativo

Figura 5. Estudo de caso

Fonte: Elaboração própria

Para que pudesse acompanhar e enviar comandos até a máquina agrícola, desenvolveu-se um aplicativo que possibilita o monitoramento e controle das mesmas. Projetou-se uma arquitetura de nuvem para conectar as

máquinas agrícolas com o aplicativo, sendo que a mesma ficou estruturada com 6 serviços da AWS, permitindo assim o monitoramento e envio de dados às máquinas.

Primeiramente, as mensagens chegam pelo protocolo MQTT no serviço Aws Iot Core, após, estas mensagens são monitoradas em tempo real pelo aplicativo desenvolvido. Na figura 6 pode-se observar a arquitetura proposta da AWS.

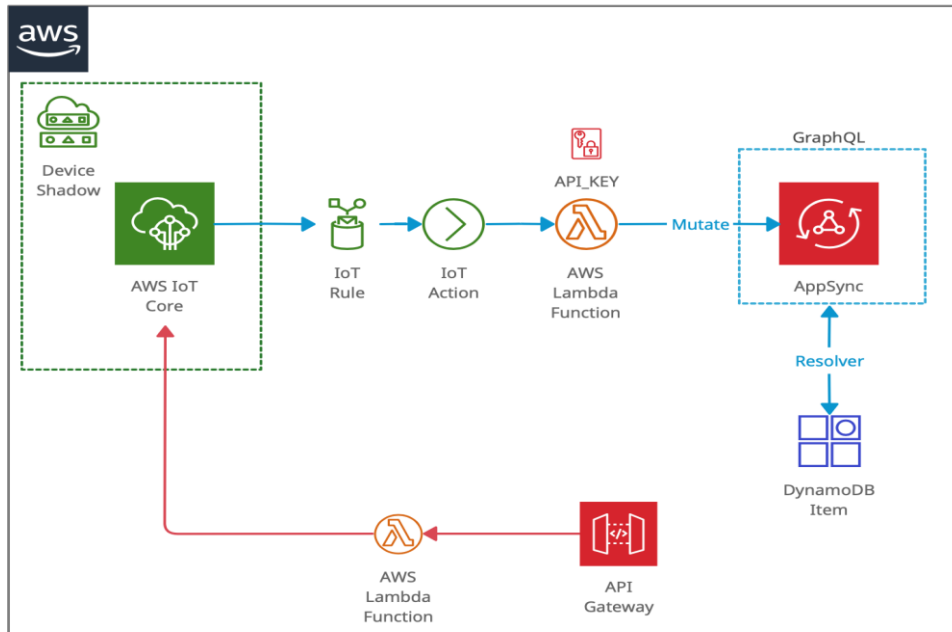


Figura 6. Arquitetura proposta AWS

Fonte: Elaboração própria

Como utilizou-se o serviço Device Shadow para manter os dados sincronizados entre máquina, banco de dados e aplicativo, a comunicação se fez entre tópicos reservados, ou seja, que possuem o prefixo "\$aws/things/" e não podem ser utilizados em outras aplicações. A partir disso, o fluxo de comunicação pode ser visto na figura 7. Para entender o fluxo de envio e recebimento de dados entre máquinas agrícolas e aplicativos, pode ser verificado na figura 7, onde é apresentado o “passo a passo”, no qual os passos que começam com a letra "A", indicam o fluxo de envio de dados da máquina para o aplicativo, e os passos que começam com a letra "B" indicam o fluxo de envio de dados do aplicativo para a máquina.

Primeiramente, a máquina agrícola representada pelo elemento "IoT Machine", publica os valores das variáveis em análise no tópico, "\$AWS/things/+shadow/update", visto no primeiro passo, representado por A.1, logo após, o serviço "Aws IoT Core" se inscreve no tópico do passo A.1, aciona uma regra e ativa uma ação, que são personalizadas pelo desenvolvedor, disparando uma Lambda Function que atualiza o estado da máquina agrícola no Banco de Dados DynamoDB. Após, um evento de atualização é disparado para todos os aplicativos inscritos na API GraphQL, pelo serviço AppSync, mostrando as variáveis coletadas, velocidade, latitude e longitude no aplicativo.

O fluxo de envio de dados do aplicativo para a máquina, pode ser observado na figura 7, onde o fluxo pode ser visto representado pela letra "B". Assim, no primeiro passo (B.1), o aplicativo faz uma requisição do tipo POST por meio do elemento "API Gateway", para uma Lambda Function, que, em seguida publica os dados para o tópico no passo 2 (B.2) com os dados desejados, e, em seguida é publicado no tópico, que pode ser visto no passo B.3, com final "/delta" indicando que há mudanças requeridas, assim, a máquina que inscrita neste tópico, recebe os comandos desejados, faz as alterações necessárias (desliga ou liga motor, por exemplo), e no passo B.4 publica as alterações para o "Aws Iot Core".

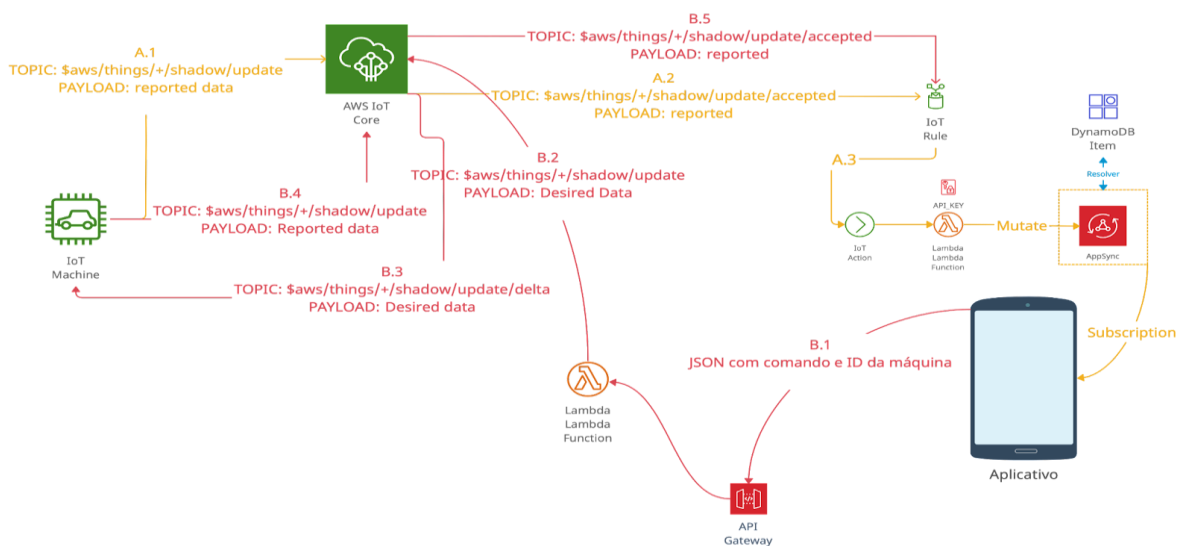


Figura 7. Fluxo de envio e recebimento de dados de uma máquina agrícola

Fonte: Elaboração própria

No aplicativo desenvolvido para o monitoramento da máquina, os dados são mostrados em tempo real, apresentando um tempo de latência de aproximadamente 1 segundo, entre a máquina coletar, enviar à nuvem, e a nuvem enviar para o aplicativo, observando que, os dados são coletados a cada 100 milissegundos pelo hardware. Para que o aplicativo envie dados para a máquina, obteve-se um tempo de latência de aproximadamente 0,5 segundos, porém no primeiro envio após a abertura do aplicativo, o tempo foi de até 6 segundos entre o aplicativo e a máquina.

**CONCLUSÃO:** Este trabalho analisou uma arquitetura de nuvem da Amazon Web Services para telemetria em máquinas agrícolas, utilizando uma estrutura modular, onde cada módulo é representado por um serviço da AWS. Foi realizado um estudo de caso, onde comandos foram enviados às máquinas e dados de velocidade, latitude e longitude foram coletados e monitorados por um aplicativo, com o intuito de observar o comportamento da arquitetura.

Percebe-se que a arquitetura de telemetria analisada se apresentou escalável, ou seja, pelo fato de ter sido projetada modularmente, ela permite a alteração, remoção ou inserção de novos serviços conforme a necessidade e demanda individuais.

No estudo de caso, o fluxo de envio de dados da máquina para o aplicativo, se mostrou aceitável, uma vez que o tempo entre a máquina coletar e enviar ao aplicativo foi de aproximadamente 1 segundo, o que não interfere no monitoramento das máquinas. Para o envio de comandos do aplicativo para a máquina, foi apresentado um delay de aproximadamente 0,5 segundos, o que é admissível, porém no primeiro envio após a abertura do aplicativo, o tempo de atraso pode levar até 6 segundos para chegar até máquina, o que dependendo da situação pode ser inadmissível, uma vez que, se o comando for, por exemplo, ordenar para que a máquina pare de andar, pode causar contratemplos. Além disso, percebe-se que esse atraso acontece entre a requisição do aplicativo e o serviço API Gateway

Também com a arquitetura analisada, percebeu-se que a mesma atende a necessidade de ter o gerenciamento de máquinas agrícolas, podendo contribuir com a produtividade, já que o produtor pode ter acesso ao monitoramento em tempo real de todas as máquinas para melhor administrar a logística da propriedade. Dados como velocidade, latitude e longitude são variáveis que estão sendo monitoradas através desse trabalho, porém novas podem ser adicionadas conforme a necessidade da máquina agrícola. Por exemplo, adicionar o monitoramento da quantidade de insumo de um pulverizador, para que o gerente da fazenda possa enviar uma máquina para abastecê-lo no momento adequado, e na posição exata.

Para a conexão entre máquina e nuvem, foi utilizado o protocolo MQTT, no qual envia e recebe mensagens no formato JSON, criptografadas pelo TLS, porém é viável experimentar o uso de formatos binários, tornando o tamanho da mensagem MQTT com menos bytes do que o utilizado no presente trabalho.

Uma das limitações da estrutura analisada na parte de monitoramento, foi que os dados são "perdidos" quando a máquina está sem conexão com a internet, pois o nível de qualidade de serviço (QoS) utilizado no protocolo MQTT foi o nível 0, por essa razão é indicado realizar novos testes utilizando níveis 1 ou 2 de QoS, para se obter a confirmação de entrega da mensagem até a nuvem. Com essa confirmação, é possível armazenar na máquina as mensagens não enviadas, e enviá-las no momento em que a conexão com a internet for restabelecida. Para trabalhos futuros, é apropriado estudar serviços da AWS para auxiliar no armazenamento e na análise de dados, com o objetivo de fornecer insights para os agricultores.

Portanto, conclui-se que a arquitetura em nuvem analisada, juntamente com o estudo de caso a campo, cumpriu o objetivo principal, onde foi possível estruturá-la de maneira modular e escalável. Também, o fluxo de envio de dados se apresentou adequado para o monitoramento e, conseqüentemente, para o gerenciamento das máquinas, porém o envio de dados para as máquinas se apresentou inviável, uma vez que o tempo de atraso não é adequado para a situação, logo se faz necessário buscar novos serviços para refazê-lo. Já para o protocolo MQTT utilizado na comunicação entre máquina e nuvem, conclui-se que o mesmo se demonstrou apropriado para a situação, não influenciando no tempo de atraso das mensagens transmitidas.

## REFERÊNCIAS

AMAZON WEB SERVICES, INC. OR ITS AFFILIATES. AWS IoT security. Disponível em: <<https://docs.aws.amazon.com/iot/latest/developerguide/iot-security.html>>. Acesso em: 11 nov 2021a.

AMAZON WEB SERVICES, INC. OR ITS AFFILIATES. Estudo de caso AWS: Divisão de Agricultura da Hexagon. Disponível em: <<https://aws.amazon.com/pt/solutions/case-studies/hexagon/>>. Acesso em: 11 nov 2021b.

AMAZON WEB SERVICES, INC. OR ITS AFFILIATES. FreeRTOS™ Real-time operating system for microcontrollers. Disponível em: <<https://www.freertos.org>>. Acesso em: 1 nov 2021 c.

AMAZON WEB SERVICES, INC. OR ITS AFFILIATES. Histórias de sucesso de clientes. Disponível em: <<https://aws.amazon.com/pt/solutions/case-studies/>>. Acesso em: 10 nov 2021d.

AMAZON WEB SERVICES, INC. OR ITS AFFILIATES. O que é o AWS Lambda? Disponível em: <[https://docs.aws.amazon.com/pt\\_br/lambda/latest/dg/welcome.html](https://docs.aws.amazon.com/pt_br/lambda/latest/dg/welcome.html)>. Acesso em: 3 nov 2021e.

AMAZON WEB SERVICES, INC. OR ITS AFFILIATES. Serviço Device Shadow do AWS IoT. Disponível em: <[https://docs.aws.amazon.com/pt\\_br/iot/latest/developerguide/iot-device-shadows.html](https://docs.aws.amazon.com/pt_br/iot/latest/developerguide/iot-device-shadows.html)>. Acesso em: 1 nov 2021 f.

AMAZON WEB SERVICES, INC. OR ITS AFFILIATES. Modo de capacidade de leitura/gravação. Disponível em: <[https://docs.aws.amazon.com/pt\\_br/amazondynamodb/latest/developerguide/HowItWorks.ReadWriteCapacityMode.html](https://docs.aws.amazon.com/pt_br/amazondynamodb/latest/developerguide/HowItWorks.ReadWriteCapacityMode.html)>. Acesso em: 4 nov 2021 g.

BARROS, M. MQTT - Protocolos para IoT. Disponível em: <<https://www.embarcados.com.br/mqtt-protocolos-para-iot/>>. Acesso em: 7 nov 2021.

COMPONENTS101. ESP32 - DevKitC. Disponível em: <<https://components101.com/microcontrollers/esp32-devkitc>>. Acesso em: 8 nov 2021.

ESPRESSIF SYSTEMS CO., LTD. ESP32-DevKitC. SHANGHAI. Disponível em: <<https://www.espressif.com/en/products/devkits/esp32-devkitc>>. Acesso em: 9 nov 2021.

HIVEMQ GMBH. Car-Sharing Application relies on HiveMQ for Reliable Connectivity. Disponível em: <<https://www.hivemq.com/case-studies/bmw-mobility-services/>>. Acesso em: 17 nov 2021.

IOT ATLAS. Command - MQTT Topics. . [S.l: s.n.]. Disponível em: <<https://iotatlas.net/en/implementations/aws/command/command1/>>. Acesso em: 14 nov 2021. , 3 Nov 2021

MQTT. MQTT: The Standard for IoT Messaging. Disponível em: <<https://mqtt.org>>. Acesso em: 4 nov 2021.

SRIVASTAVA, A. e DAS, D. K. A Comprehensive Review on the Application of Internet of Thing (IoT) in Smart Agriculture. Wireless Personal Communications, 25 Ago 2021. Acesso em: 2 nov 2021.

THOMPSON, N. M.; DELAY, N. D. e MINTERT, J. R. Understanding the farm data lifecycle: collection, use, and impact of farm data on U.S. commercial corn and soybean farms. Precision Agriculture, v. 22, 24 Abr 2021. Acesso em: 4 nov 2021.

U-BLOX AG. NEO-6 Series. Disponível em: <[https://www.u-blox.com/sites/default/files/products/documents/NEO-6\\_ProductSummary\\_%28GPS.G6-HW-09003%29.pdf](https://www.u-blox.com/sites/default/files/products/documents/NEO-6_ProductSummary_%28GPS.G6-HW-09003%29.pdf)>. Acesso em: 17 nov 2021.

# SISTEMA EMBARCADO DE COLETA DE DADOS PARA GERAÇÃO DE MAPAS DE PRODUTIVIDADE EM FRUTICULTURA

Ricardo Sobjak<sup>1</sup>; Paula Leticia Souza de Moura<sup>2</sup>; Eduin Nasael Torres Avila<sup>3</sup>; Luciano Gebler<sup>4</sup>; Claudio Leones Bazzi<sup>1</sup>

<sup>1</sup>Computação (Dr. Engenharia Agrícola), Professor - Universidade Tecnológica Federal do Paraná (UTFPR), Campus Medianeira, Medianeira, PR. ricardosobjak@utfpr.edu.br / (45) 9 9813-2650; <sup>2</sup>Eng<sup>a</sup> Eletricista, Estudante (Graduação) - Universidade Tecnológica Federal do Paraná, Campus Medianeira, Medianeira, PR; <sup>3</sup>Eng<sup>o</sup> Agrônomo, Mestrando em Tecnologias Computacionais para o Agronegócio - Universidade Tecnológica Federal do Paraná (UTFPR), Campus Medianeira, Medianeira, PR; <sup>4</sup>Eng<sup>o</sup> Agrônomo, Pesquisador - Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA), EMBRAPA Uva & Vinho, Vacaria, RS

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Dada a expansão na utilização de áreas para agricultura, surge a necessidade de implementar estratégias eficientes em relação ao monitoramento da produtividade das culturas, visando um melhor acompanhamento e manejo das áreas produtoras para que se busque o máximo potencial produtivo. Neste sentido, o presente trabalho visa apresentar um sistema embarcado que possibilita a coleta de dados de produtividade para aplicação em áreas cultivadas com frutas, onde a colheita é realizada de forma manual. O sistema foi desenvolvido e testado em pomares de maçãs, obtendo-se o posicionamento do trabalhador durante a colheita e a identificação das caixas onde os frutos são descarregados. Dois métodos de interpolação foram implementados em um software que permite a criação de mapas de produtividade por meio da integração com a plataforma AgDataBox.

**PALAVRAS-CHAVE:** agricultura de precisão; geoestatística; cultura perene

## DATA COLLECTION EMBEDDED SYSTEM DEVELOPMENT FOR THE GENERATION OF YIELD MAPS

**ABSTRACT:** Given the expansion in the use of areas for agriculture, there is a need to implement efficient strategies for monitoring crop productivity, aiming at better producing areas monitoring and management to seek the maximum productive potential. In this sense, this work aims to present an embedded system for the yield data collection for application in areas cultivated with fruits, where harvesting is carried out manually. The system was developed and tested in apple orchards, obtaining the worker positioning during the harvest and the boxes identification where the fruits will be unloaded. The software has two interpolation methods implemented allowing the yield maps creation through integration with the AgDataBox platform.

**KEYWORDS:** precision agriculture; geostatistics; perennial culture

**INTRODUÇÃO:** O crescente desenvolvimento de sistemas agrícolas comerciais desempenha um papel importante no crescimento econômico brasileiro, resultando em um complexo desafio de escalar as culturas energéticas e alimentares de forma sustentável, garantindo um crescimento a longo prazo (AZEVEDO JUNIOR et al., 2022; MARTINELLI et al., 2010; PELLEGRINA, 2022). Nesse sentido, com o constante crescimento especialmente no cultivo de culturas perenes, tem surgido alguns desafios relacionados ao manejo, pois essas culturas exigem um acompanhamento especial e muito efetivo, uma vez que grande parte do trabalho de campo ocorre de forma manual inviabilizado em muitos casos o uso de tecnologias nas áreas de produção (ROY et al, 2019).

Por outro lado, também se faz necessário resgatar a percepção da capacidade de identificar diferenças no solo e no relevo das áreas cultivadas em pequenas propriedades rurais nas quais as atividades de agrícolas de ciclo curto ou semiperenes são realizadas de forma manual e necessitando de tratamentos distintos (MOLIN et al., 2015). Para otimizar sustentabilidade no campo, mitigando os impactos ambientais e maximizando a

lucratividade, a agricultura de precisão (AP) oferece inúmeras decisões por unidade de área e por unidade de tempo com benefício líquido associado (COBBENHAGEN et al., 2021; XU et al., 2022; TAN et al., 2022). Dessa maneira, entre os diversos aportes tecnológicos a geostatística trata do estudo da variabilidade espacial de uma determinada área por meio da coleta de dados e utilização de modelos matemáticos apropriados (MULLA, 2012). Assim, as coletas de dados de produtividade, em áreas de cultivo, podem ser exploradas combinando dispositivos eletrônicos de georreferenciamento, sistemas de armazenamento e leitura de informações, com objetivo de mapear a produtividade, mesmo quando a colheita necessariamente precisa ser realizada de forma manual.

Considerando que a eletrônica embarcada é amplamente aplicada em maquinário agrícola (ABBASI et al., 2022; BOURSIANIS et al., 2022), a quantidade de empresas brasileiras que de fato incorporam essa ferramenta de tecnologia da informação não é expressiva no mercado destinado a pequenos processos manuais de atividade agrícola. Nesse sentido, este trabalho apresenta o desenvolvimento de um sistema embarcado que permite realizar a coleta de dados de operações de colheitas manuais, a fim de gerar mapas de produtividade para fruticultura.

**MATERIAIS E MÉTODOS:** O processo de coleta de dados para os talhões de uma área de pomares de maçã foi realizado por meio de um sistema embarcado de rastreamento. O dispositivo eletrônico desenvolvido possui um receptor de sinal de sistema de posicionamento global, que coleta as coordenadas geográficas, um leitor de identificador de rádio frequência e um sistema de armazenamento dos dados em cartão de memória micro SD. Estes módulos foram interligados por meio de uma placa de circuito impresso, sendo controlados por um módulo ESP32, administrado por software que implementa a leitura e controle dos sinais por meio da IDE do *Arduínofootnotemark*. O microcontrolador ESP32 possui tecnologia *bluetooth* já incorporada ao módulo, o que permite outra forma de transmissão de dados além do armazenamento em cartão micro SD.

O protótipo de dispositivo desenvolvido possui um número de identificação e foi acoplado às sacolas de coletas de maçã utilizadas por trabalhadores, que realizam a colheita manual dos frutos. Essas sacolas podiam variar entre 12 a 18 quilogramas quando totalmente cheias, sendo as mesmas descarregadas nas caixas colocadas previamente em locais estratégicos no pomar. Essa variação de peso ocorre, pois, dependendo do funcionário, da distância entre o funcionário e a caixa, e se o mesmo está colhendo com ou sem auxílio de escada. Os frutos colhidos foram descarregados em caixas que também possuem identificação a partir de um cartão RFID, e que diferenciam cada caixa. No momento da descarga feita pelo coletor, o módulo RFID do equipamento presente na sacola recebe o sinal do cartão RFID acoplado à caixa. Assim, um registro em arquivo de texto armazena os dados no cartão de memória micro SD, permitindo posteriormente a identificação do número da caixa e quantidade de descarregamentos feitas nela. A distância entre as caixas fixas na linha, variava entre 5 a 10 metros de distância uma da outra, dependendo do tamanho do pomar e da quantidade de coletores. As caixas móveis foram utilizadas em pomares integrados aos *packings-houses*, e estavam dispostas em uma plataforma sendo conduzidas por um trator. O receptor GPS também fornece leitura do posicionamento (latitude e longitude) do funcionário em intervalos de tempo determinados, bem como a data e hora corrente no momento da coleta. Esses dados foram importados para um sistema de armazenamento e utilizados para geração de mapas de produtividade por meio de técnicas de estimativa de produtividade (BAZZI et al., 2021).

Como o sistema foi utilizado para testes em campo, a alimentação do hardware foi feita com duas baterias recarregáveis Íon de Lítio *Li-Ion*, modelo 18650 de 4,2V, com capacidade de carga de 9800mAh cada, ligadas em paralelo para aumentar a autonomia do equipamento. Entretanto, a soma das capacidades individuais das baterias, que é conveniente para aumentar o tempo de funcionamento do dispositivo em campo, acarreta na necessidade de abaixar a tensão de saída da ligação paralela para alimentar a PCI, que tem todos os módulos dependentes de alimentação em 3,3V. Portanto, foi escolhido um módulo abaixador Buck Step-Down para modular a tensão de saída das baterias de 4,2V para 3,3V. A escolha por este módulo se deve ao fato da sua alta eficiência de conversão em relação a um Circuito Integrado (CI) 1117, ultrapassando a taxa de 90% nos níveis de tensão utilizados na presente aplicação.

Finalizado a colheita da área correspondente, se inicia a execução das funcionalidades previstas no sistema, tais como: cadastro da amostra e os procedimentos de execução de análise estatística, interpolação de dados por meio dos métodos Krigagem ordinária ou inverso da distância ponderada (IDP), e a apresentação de mapas de produtividade da área/talhão. Esses processos, são realizados de forma transparente pelo sistema, que realiza



a requisição para a API *AgDataBox* e obtém os resultados requeridos. Após a geração dos mapas de produtividade, os mesmos são armazenados no banco de dados e estão disponíveis para acesso e visualização das informações espaciais.

**RESULTADOS E DISCUSSÃO:** O circuito esquemático da PCI confeccionada é apresentado na Figura 1. Observa-se no centro, o módulo ESP32, saídas para o módulo RFID, para o módulo GPS, de modelo GPS GY-NEO6MV2 e para a conexão do módulo de leitura de cartão micro SD. Por último, a alimentação da PCI é mostrada com conector de entrada para as baterias, passando por um fusível de proteção contra sobrecarga, e finalmente, pelo módulo rebaixador *Buck Step-Down* que fornece o nível de tensão adequado para o funcionamento do restante da PCI em 3,3V.

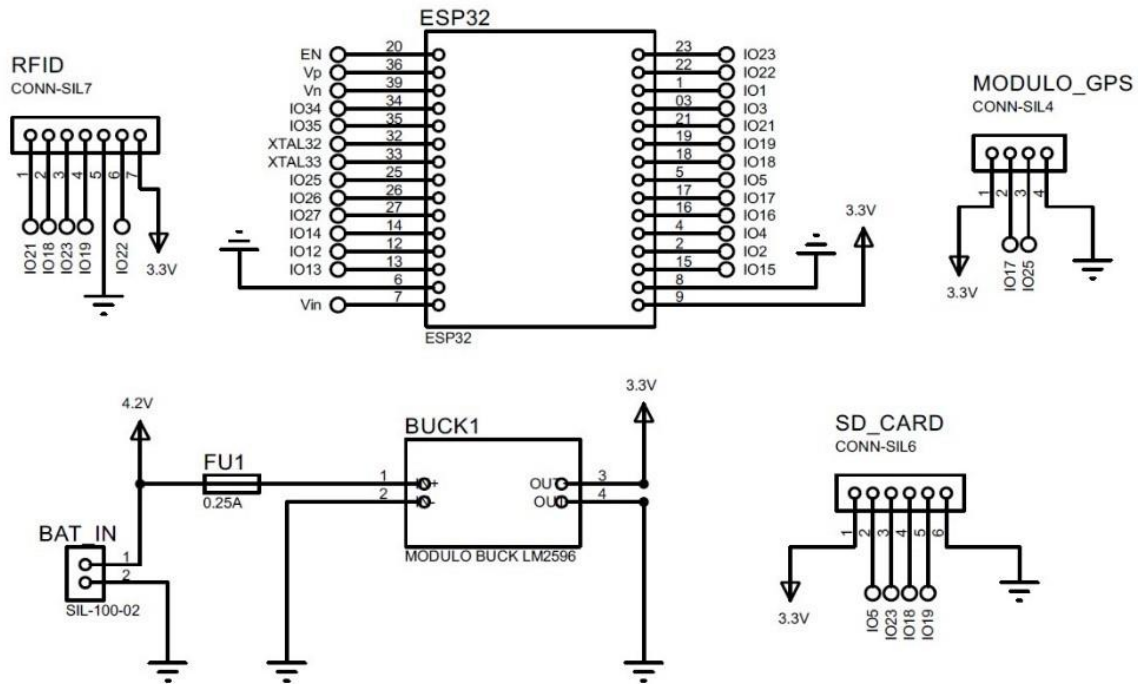


Figura 1. Circuito esquemático para a PCI do sistema embarcado.

O resultado desse circuito é mostrado na projeção em 3D na Figura 2, medindo 60 mm de comprimento por 40 mm de largura. Isso possibilita o enclausuramento da eletrônica embarcada em uma caixa Patola de modelo PB-07, garantindo a proteção do circuito contra umidade, poeira e impactos causados pelo usuário no momento da coleta de frutas.




Figura 2. Projeção do layout da PCI.

Desse modo o projeto ganha proporções relativamente pequenas, que não atrapalham o trabalho dos funcionários que utilizarão o dispositivo durante a colheita. Com o mesmo objetivo de otimização de espaço, escolheu-se executar a PCI em placa de fibra de vidro dupla face de cobre, que reduz o espaço necessário para conexão dos módulos. A análise geoestatística em sua essência contém como característica principal o semivariograma. Nesse sentido, a API *AgDataBox* processa as representações gráficas, sendo a primeira, envolvendo os 12 (doze) melhores modelos que foram selecionados durante as comparações efetuadas pela API (exponencial, esférico, gaussiano e família Matérn). O sistema apresenta uma tabela contendo todos os registros das análises realizadas, sendo as informações (código, modelo e método, contendo os valores de ICE, de contribuição, de alcance, do valor kappa, erro médio, desvio padrão e o valor da ISI) são armazenadas e processadas requisitando a API para a interpolação de dados pelo método de Krigagem ordinária.

Testes experimentais foram realizados em Vacaria, RS, Brasil em duas áreas de cultivo de maçã. Após a etapa de colheita e processamento dos dados coletados no campo foi possível gerar um layout geográfico dos dados obtidos por meio do sistema embarcado, conforme mostra a Figura 3.




Figura 3. Mapas de mobilidade dos colhedores com dados das colheitas ocorridas nos dias 16 e 17 de janeiro de 2020. Cada ponto observado indica a localização das sacolas de colheita .

Cada ponto colorido representa uma posição obtida pelo aparelho nos momentos em que a colheita estava sendo realizada. As diferentes cores representam as diferentes sacolas de colheita. Observa-se que existe na imagem uma sobreposição de pontos, esse efeito ocorre devido a quantidade de funcionários transportando o sistema embarcado em uma mesma linha de colheita devido a colheita simultânea. Todavia em trabalhos futuros o sistema deve ser otimizado para minimizar esse problema e permitir maior visibilidade da mobilidade sobre a área processada.

O sistema desenvolvido fazendo uso de tecnologias computacionais, é capaz de armazenar os dados de colheita de culturas perenes, coletadas por meio de um dispositivo eletrônico de rastreamento, e executar dois métodos que buscam estimar a produtividade da área. O cálculo da estimativa da produtividade é executado a partir de um conjunto de dados que representam uma amostra, referente aos dados de colheita. Por meio da integração do sistema com a API *AgDataBox*, realizou-se a análise geoestatística dos dados, bem como a geração de mapas de produtividade (Figura 4) fazendo uso de métodos tradicionais de interpolação (Krigagem ordinária e IDP). Os resultados apresentados foram obtidos provando duas formas na qual o sistema desenvolvido poder ser utilizado. (I) o primeiro método consiste no cálculo da produtividade obtida com referência as caixas de armazenamento. Neste método, como cada sacola demora um certo período para ser enchida e, portanto, tem-se uma sequência de pontos de localização dos locais onde as frutas foram colhidas, realiza-se o cálculo do centroide destes pontos, indicando que neste local uma sacola foi colhida. (II) O segundo método consiste na produtividade obtida com referência a uma grade amostral que representa as árvores do pomar. Neste sentido, visando simular as árvores de um pomar, este método busca criar uma grade amostral inicial e relacionar cada ponto que representa o momento da colheita a um ponto da grade amostral mais próximo da localização do

mesmo. Dessa forma, as estimativas de produtividade foram geradas para esses dois métodos conforme utilizando anteriormente (BAZZI et al. 2021). Observou-se nesse trabalho que quando o método 1 foi utilizado para estimar a produtividade, o número de elementos amostrais (20 pontos amostrais para cada parcela) foi um fator limitante para a confecção do semivariograma experimental para interpolação por Krigagem ordinária. No entanto o método 2 foi mais eficiente devido ao maior número de pontos amostrais (112 para o campo A e 70 para o campo B).




Figura 4. Mapas de produtividade gerados com dados das colheitas realizadas nos dias 16 e 17 de janeiro de 2020 interpolados por Krigagem ordinária (Método 2).

**CONCLUSÃO:** Nesse estudo desenvolveu-se um sistema embarcado que possibilita a coleta e armazenagem de dados de interesse, para análises geoestatísticas. O sistema embarcado desenvolvido permite realizar a coleta e armazenamento de dados que podem ser utilizados, para a geração de mapas temáticos de produtividade. Isso por meio dos mecanismos de georreferenciamento e identificação das caixas que recebem a colheita de maçãs. Além disso, o planejamento do hardware para a especificação de longa autonomia possibilitará o uso do equipamento em campo com previsão de duração de carga das baterias por 24 horas. Por meio da combinação do dispositivo eletrônico de rastreamento hardware em sacolas de colheita de frutas e o sistema web utilizado nesse estudo foi possível realizar o processo de importação, armazenagem, análise geoestatística e interpolação de dados para a geração de mapas temáticos referentes a produtividade de culturas perenes, visando maximizar a produtividade em diferentes locais da área/talhão.

#### AGRADECIMENTOS:

Os autores agradecem o Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), ao Parque Tecnológico Itaipu – FPTI/BR e à Fundação Araucária pelo aporte financeiro e a concessão de bolsas de estudo e materiais utilizados na construção do protótipo. À Empresa Brasileira de Pesquisa Agropecuária (Embrapa) - Uva & Vinho e à Universidade Tecnológica Federal do Paraná - Campus Medianeira pelo suporte referente a pesquisa desenvolvida.

#### REFERÊNCIAS

ABBASI, R.; MARTINEZ, P.; AHMAD, R. The digitization of agricultural industry – a systematic literature review on agriculture 4.0. **Smart Agricultural Technology**, v.2, p.100042, 2022.

AZEVEDO JUNIOR, W.C.; RODRIGUES, M.; SILVA, D.C.C. Does agricultural efficiency contribute to slowdown of deforestation in the Brazilian Legal Amazon?. **Journal for Nature Conservation**, v.65, p.126092, 2022.

- BAZZI, C.L.; CORDEIRO, B.E.; GEBLER, L., SOUZA, E.G.; SCHENATTO, K.; FILHO, P.L.P.; SOBJAK, R. Yield map generation of perennial crops for fresh consumption. **Precision Agriculture**, v.23, p.698–711, 2021.
- BOURSIANIS, A.D.; PAPADOPOULOU, M.S.; DIAMANTOULAKIS, P.; LIOPA-TSAKALIDI, A.; BAROUCHAS, P.; SALAHAS, G.; KARAGIANNIDIS, G.; WAN, S.; GOUDOS, S.K. Internet of Things (IoT) and Agricultural Unmanned Aerial Vehicles (UAVs) in smart farming: A comprehensive review. **Internet of Things**, v.18, p.100187, 2022.
- COBBENHAGEN, A.T.J.R.; ANTUNES, D.J.; VAN DE MOLENGRAFT, M.J.G.; HEEMELS, W.P.M.H. Opportunities for control engineering in arable precision agriculture. **Annual Reviews in Control**, v.51, p.47-55, 2021.
- MARTINELLI, L.A.; NAYLOR, R.; VITOUSEK, P.M.; MOUTINHO, P. Agriculture in Brazil: impacts, costs, and opportunities for a sustainable future. **Current Opinion in Environmental Sustainability**, v.2, p.431-438, 2010.
- MOLIN, J. P.; AMARAL, L. R.; COLAÇO, A. **Agricultura de precisão**. [S.l.]: Oficina de textos, 2015.
- MULLA, D.J. Chapter 20 - Modeling and Mapping Soil Spatial and Temporal Variability, In: Lin, H. (Ed.), **Hydrogeology**. Academic Press, Boston, pp.637-664, 2012.
- PELLEGRINA, H.S. Trade, productivity, and the spatial organization of agriculture: Evidence from Brazil. **Journal of Development Economics**, v.156, p.102816, 2022.
- ROY, P.; KISLAY, A.; PLONSKI, P. A.; LUBY, J.; ISLER, V. Vision-based preharvest yield mapping for apple orchards. **Computers and Electronics in Agriculture**, v.164, p.104897, 2019.
- TAN, X.J.; CHEOR, W.L.; YEO, K.S.; LEOW, W.Z. Expert systems in oil palm precision agriculture: A decade systematic review Author links open overlay panel. **Journal of King Saud University - Computer and Information Sciences**, v.34, p.1569-1594, 2022.
- XU, J.; GU, B.; TIAN, G. Review of agricultural IoT technology. **Artificial Intelligence in Agriculture**, v.6, p.10-22, 2022.

# USO DE MOTORES ELÉTRICOS EM SEMEADORAS E GANHO DE PRODUTIVIDADE NA CULTURA DA SOJA

Airton Polon<sup>1</sup>

<sup>1</sup>Mestrando em Agricultura de Precisão, Mestrando em Agricultura de Precisão - UFSM, UFSM, Santa Maria, RS. airton.polon@acad.ufsm.br / (54) 9 9658-3832

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** A utilização de motores elétricos em semeadoras objetiva aumentar a eficiência dos mecanismos dosadores com a eliminação da transmissão mecânica diminuindo a interferência do conjunto no potencial produtivo da cultura. Com a aplicação desta tecnologia, é possível agregar funções capazes de determinar a correta aplicação, em quantidades e localização, de insumos de acordo com os preceitos da Agricultura de Precisão. O uso dos motores elétricos proporcionou a redução do Coeficiente de Variação, das falhas, além do aumento do número de plantas aceitáveis para as variáveis, sendo que o incremento médio de produtividade foi de 335 kg ha<sup>-1</sup>. Além disso, com os motores elétricos foi avaliada a função de compensação de curvas, este recurso garante que todas as linhas da semeadora apliquem as sementes na mesma distância, estabilizando a produtividade na mesma passada de semeadura. A pesquisa evidenciou um incremento de produtividade na ordem de 13,3% superior à não utilização da função. O resultado das análises apontou, na média, incremento de produtividade de 276,5 kg ha<sup>-1</sup> para os motores elétricos, convertido em R\$ 829,50 ha.

**PALAVRAS-CHAVE:** Coeficiente de Variação; Motor Elétrico; Produtividade

## USE OF ELECTRIC MOTORS IN SEEDERS AND GAIN PRODUCTIVITY IN SOYBEAN CULTURE

**ABSTRACT:** The use of electric motors in seeders aims to increase the efficiency of the metering mechanisms with the elimination of mechanical transmission, reducing the interference of the set in the productive potential of the crop. With the application of this technology, it is possible to add functions capable of determining the correct application, in quantities and location, of inputs according to the precepts of Precision Agriculture. The use of electric motors reduced the Coefficient of Variation, the failures, in addition to increasing the number of acceptable plants for the variables evaluated, and the average increase in productivity was 335 kg ha<sup>-1</sup>. In addition, with the electric motors, the curve compensation function was evaluated, this feature ensures that all the seeder lines apply the seeds at the same distance, stabilizing productivity in the same sowing pass. The survey showed an increase in productivity in the order of 13.3% higher than the non-use of the function. The results of the analyzes showed, on average, a productivity increase of 276.5 kg ha<sup>-1</sup> for electric motors, converted into R\$ 829.50 ha.

**KEYWORDS:** Coefficient of Variation; Electric Motor; Productivity

**INTRODUÇÃO:** A necessidade de aumentar a produtividade das lavouras de grãos está a cada dia mais evidente, assim como as oportunidades para a redução de custos de produção. Neste sentido, a qualidade de semeadura é um fator a cada dia mais debatido e fundamental. Aumentar a eficiência das semeadoras no campo é um dos fatores indispensáveis para aumento da produtividade e a garantia de retorno econômico ao final do ciclo.

As semeadoras têm por objetivo distribuir uma quantidade de sementes pré-determinada, porém este princípio de funcionamento apresenta erros de dosagem e distribuição dos insumos aplicados, segundo Biulchi (2016). Muitos desses erros ocorrem na regulação e pelos componentes destas máquinas. Em um estudo realizado com 35 semeadoras, a dosagem média de sementes variou de 0,06% a 48,94%, com uma média de 11,39%. Estes fatores contribuem para que ocorram redução na produtividade, segundo CASÃO et al (2019). Os incrementos de produtividade variaram entre 6% e 76% considerando apenas a qualidade do plantio, melhor deposição de sementes no solo significa maior a produtividade (PICHINIM, 2012).



Na avaliação de semeadoras pneumáticas e mecânicas no plantio de soja na região norte do Paraná, o Coeficiente de Variação (CV%) médio ficou em 45% e 71%, respectivamente (SCHMALZ, 2014). Esta variável interfere diretamente no potencial produtivo. De acordo com Desbesell et al (2018), as perdas produtivas em lavouras de soja com coeficiente de variação superior a 60% podem superar os 16%, ou seja, mais de 12 sacas de soja por hectare, dependendo da cultivar.


A tecnologia de motores elétricos surge no mercado de semeadoras objetivando minimizar estes problemas, substituindo o sistema de transmissão mecânica, além de oferecer uma variedade de recursos para Agricultura de Precisão, desde os mais simples aos mais complexos, tais como: aplicação em taxa variada; desligamento automático de linhas; compensação de sementes em curvas e; geração de informações que o ecossistema instalado pode enviar para plataformas em nuvem para serem trabalhados em ambientes de Agricultura Digital.

Para Dorsey (2017), em uma semeadora de 24 linhas durante a safra de milho, descobriram que as fileiras internas estavam sobrecarregadas em até 124% da população alvo, enquanto as linhas externas apresentavam apenas 81% da população alvo. Observou também que as linhas centrais tinham um rendimento superior em relação as linhas das extremidades.

O presente trabalho foi desenvolvido objetivando comparar o desempenho de uma semeadora de precisão equipada com transmissão mecânica em relação aos recursos disponibilizadas pelo acionamento por motores elétricos e os benefícios para operações em ambientes de Agricultura de Precisão.

**MATERIAIS E MÉTODOS:** Os experimentos foram implantados no município de Getúlio Vargas/RS em uma área de 2 hectares. A cultivar semeada foi a BMX Ativa na população de 323.809 plantas por hectare, ou seja, 13,6 sementes por metro linear em espaçamento de 0,42 m entre fileiras de plantas.

A semeadura foi realizada utilizando um trator marca Massey Ferguson 292 4x2 equipado com TDA e uma semeadora marca Semeato ano 2007, modelo SHM 1517 com 8 linhas de semeadura (FIGURA 1) espaçadas a 42 cm entre linhas, equipada com dosadores de semente mecânicos da própria Semeato e dosadores de fertilizantes da marca FertiSystem com Sem-Fim 2". O sistema elétrico utilizado foi o da empresa ROJ TECHNOLOGY, composto por 8 motores DMD-2 (12V) com torque de 4,5Nm para acionamento dos dosadores de semente. Estes motores são constituídos por um bloco de alumínio onde são integrados o motor elétrico com tecnologia brushless, uma redução axial e uma placa eletrônica responsável pelo gerenciamento das funções do motor e da linha de semeadura, como as estatísticas de sementes, por exemplo. Os dosadores de fertilizante permaneceram sempre acionados pela transmissão mecânica através do recâmbio e com a mesma dosagem de fertilizante, ou seja, 250 kg ha<sup>-1</sup>. A controladora (ECU) usada na pesquisa foi com tecnologia ISOBUS, modelo CM 20, marca Topcon, assim como o display e o receptor GNSS, modelos X25 e AGI-4, respectivamente. Foi empregada a correção de sinal comercialmente disponibilizada para o mercado como TOPnet. Esta opção possibilita a localização precisa do equipamento no campo, com erro aproximado de  $\approx 3$ cm, requisito necessário para o desligamento automático de linhas, por exemplo.



Uma imagem contendo motor, grande, caminhão, mesa Descrição gerada automaticamente

**FIGURA 1. Semeadora equipada com transmissão mecânica e motores elétricos linha a linha. Seeder equipped with mechanical transmission and row-by-row electric motors.**

A semeadura foi realizada em duas condições diferentes, em um determinado momento equipada com a transmissão mecânica e em seguida, com os motores elétricos fazendo o acionamento direto nos elementos dosadores. Para a semeadura com acionamento mecânico foram retirados os cabos do sistema eletrônico da bateria e para a semeadura com o acionamento pelos motores elétricos foram removidas as correntes das engrenagens integradas em cada linha de semeadura.

Foram delimitadas 32 parcelas de 25 metros de comprimento por 3,5 metros de largura, 16 parcelas para cada tratamento, ou seja, a semeadora equipada com a transmissão mecânica e 16 parcelas com a semeadora equipada com os motores elétricos. Foram avaliadas quatro variáveis dentro de cada tratamento, sendo 4, 5, 6 e 7 km h<sup>-1</sup>, com quatro repetições para cada variável.

Para cada repetição foram feitas medições e contagens de plantas em duas linhas de plantio na distância de 5 metros em cada linha, totalizando 10 metros de medições em cada repetição, para avaliação e cálculo do percentual do Coeficiente de Variação, do número de falhas, duplas e de aceitáveis. Para determinar a produtividade, foram colhidas a totalidade das parcelas, além de amostragens de plantas para geração de dados e posteriores comparativos.

Para a avaliação dos tratamentos com e sem compensação de curvas, possível apenas para a máquina operando com os motores elétricos, foram feitas determinações da população de plantas com três repetições para a Linha Interna (L.I), Linha Central (L.C) e Linha Externa (L.E) no plantio Com Compensação de Curvas (C.C.C) e Sem Compensação de Curvas (S.C.C) para determinar a população de plantas em cada uma das linhas nos dois tratamentos com o objetivo de cruzar estas informações e determinar a produtividade.

O raio da curva onde foram coletados os dados foi de 30 metros, a contagem de plantas ocorreu em 10 metros lineares e a avaliação de produtividade ocorreu com a coleta, debulha e pesagem das plantas em 5 metros lineares para cada repetição.

O delineamento experimental utilizado nesta pesquisa foi o de blocos inteiramente casualizados e para o processamento da estatística descritiva foi usado o software gratuito SISVAR<sup>®</sup>.

**RESULTADOS E DISCUSSÃO:** O plantio da área do experimento para avaliação da eficiência de semeadura foi no dia 27 de dezembro de 2019, enquanto a semeadura da área para a avaliação das funções C.C.C e S.C.C foi realizada no dia 7 de janeiro de 2020. A colheita das parcelas para avaliação dos sistemas de transmissão mecânico (MEC) e do acionamento elétrico (ELE) foi realizada no dia 29 de abril e a colheita da lavoura onde foi realizada a avaliação dos tratamentos C.C.C e S.C.C foi realizada no dia 07 de maio de 2020 onde a precipitação pluvial total durante o ciclo da cultura foi de 450 mm e 316 mm respectivamente.

Os resultados da análise estatística estão apresentados na Tabela 01, onde os dados de produtividade, CV%, Falhas, Duplas e Aceitáveis são relacionados.

**TABELA 01. Resultado da análise estatística para avaliar o efeito da velocidade e do respectivo Coeficiente de Variação (CV%) entre as plantas em cada tratamento sobre a produtividade da cultura da soja. Result of the statistical analysis to evaluate the effect of the speed and the respective Coefficient of Variation (CV%) among the plants in each treatment on the productivity of the soybean crop.**

PRODUTIVIDADE (kg ha <sup>-1</sup> )						
Transmissão	CV% (estatística)	Média kg ha <sup>-1</sup>	4 km h <sup>-1</sup>	5 km h <sup>-1</sup>	6 km h <sup>-1</sup>	7 km h <sup>-1</sup>
Elétrica	5,0%	2,688 a	2,626 aA	2,940 aA	2,619 aA	2,567 aA
Mecânica		2,353 b	2,373 bA	2,553 bA	2,418 bA	2,069 bA

<b>COEFICIENTE DE VARIAÇÃO (%)</b>						
Transmissão	CV% (estatística)	Média CV%*	4 km h <sup>-1</sup>	5 km h <sup>-1</sup>	6 km h <sup>-1</sup>	7 km h <sup>-1</sup>
Elétrica	9,2%	45,3% b	44,0% aA	40,8% bA	47,0% aA	49,3% bA
Mecânica		52,4% a	49,8% aA	49,0% aA	53,3% aA	57,8% aA
<b>FALHAS (%)</b>						
Transmissão	CV% (estatística)	Média Falhas	4 km h <sup>-1</sup>	5 km h <sup>-1</sup>	6 km h <sup>-1</sup>	7 km h <sup>-1</sup>
Elétrica	30,8%	10,3% b	8,8% bAB	2,8% bB	13,3% aA	16,3% bA
Mecânica		18,0% a	16,5% aA	15,8% aA	16,6% aA	23,3% aA
<b>DUPLAS (%)</b>						
Transmissão	CV% (estatística)	Média Duplas	4 km h <sup>-1</sup>	5 km h <sup>-1</sup>	6 km h <sup>-1</sup>	7 km h <sup>-1</sup>
Elétrica	30,8%	16,9% a	16,3% bA	16,3% bA	16,5% aA	17,5% bA
Mecânica		18,7% a	16,5% aA	17,3% aA	21,5% aA	20,5% aA
<b>ACEITÁVEIS (%)</b>						
Transmissão	CV% (estatística)	Média Aceitáveis	4 km h <sup>-1</sup>	5 km h <sup>-1</sup>	6 km h <sup>-1</sup>	7 km h <sup>-1</sup>
Elétrica	10,6%	72,9% a	74,8% aA	80,0% aA	70,3% aA	66,5% bA
Mecânica		63,3% b	67,3% bA	68,0% bA	62,8% aA	56,5% aA
*CV% – Coeficiente de Variação. Médias seguidas das mesmas letras minúsculas nas colunas ou maiúsculas nas linhas não se diferem pelo teste de Tukey a 5%.						

Ficou evidenciado que há diferença significativa de produtividade entre a semeadora com Transmissão Elétrica e a semeadora com Transmissão Mecânica, 2,688 kg ha<sup>-1</sup> e 2,353 kg ha<sup>-1</sup>, respectivamente. A transmissão através de motores elétricos apresentou produtividade média de 335 kg ha<sup>-1</sup> superior ao acionamento mecânico no total do experimento, isto é, nas quatro variáveis em estudo, como é possível visualizar graficamente na Figura 2.

Para todas as variáveis, ou seja, as 4 velocidades, houve significativa diferença com produtividade superior para a máquina com transmissão por motores elétricos, sendo 253 kg ha<sup>-1</sup>, 387 kg ha<sup>-1</sup>, 201 kg ha<sup>-1</sup> e 498 kg ha<sup>-1</sup> para 4 km h<sup>-1</sup>, 5 km h<sup>-1</sup>, 6 km h<sup>-1</sup> e 7 km h<sup>-1</sup>, respectivamente.






FIGURA 2. Resposta em produtividade para as diferentes velocidades nos dois tratamentos. **Yield response for the different speeds in the two treatments.**

A análise do CV% seguiu os mesmos resultados da avaliação de produtividade, com exceção para as velocidades de 4 km h<sup>-1</sup> e 6 km h<sup>-1</sup> que não se diferiram entre os tratamentos, ou seja, transmissão através de motores elétricos e transmissão mecânica. Ao comparar os dois gráficos é possível identificarmos uma relação muito íntima entre o CV% e a produtividade, ou seja, quanto menor o CV%, maior a produtividade e vice-versa. Dentro do próprio tratamento, o CV% não teve diferença significativa entre as variáveis. Na Figura 3 é possível verificar que o CV% é crescente para ambas as formas de acionamento na medida em que a velocidade é aumentada.




FIGURA 3. Comportamento do CV% para as diferentes velocidades nos dois tratamentos. **Behavior of the CV% for the different speeds in the two treatments.**

A análise para a determinação de informações da eficiência de semeadura foi embasada na metodologia publicada pela ABNT (1996) em que considera os seguintes padrões: aceitáveis são todos os espaçamentos entre sementes de que ficam de 0,5 a 1,5 vezes o espaçamento médio. Os valores obtidos abaixo do limite de 0,5 vez são considerados como espaçamentos duplos ou múltiplos, enquanto espaçamentos acima de 1,5 vez o espaçamento médio são considerados falhas de semeadura.

O gráfico na Figura 4 apresenta a superioridade do número de falhas para o acionamento através da transmissão mecânica, conforme demonstrado na análise estatística onde o número de falhas para o acionamento por motores elétricos ficou, na média, 75% inferior. Apenas na variável de 6 km h<sup>-1</sup> não houve diferença estatística

entre os dois tratamentos avaliados. Dentro do próprio tratamento, o acionamento por motores elétricos diferiu na velocidade de 5 km h<sup>-1</sup>.




FIGURA 4. Evidência do percentual de falhas para as diferentes velocidades nos dois tratamentos. **Evidence of failures for different speeds in the two treatments.**

A avaliação do número de duplas dentro de cada tratamentos não se diferenciou estatisticamente, inclusive não apresentou diferença entre os dois tratamentos também. Mesmo assim, na Figura 5 pode-se perceber que, apesar de não haver diferença estatística significativa, a medida em que a velocidade é aumentada, a tendência é de distanciamento com maior número de duplas para o sistema de acionamento mecânico.




FIGURA 5. Evidência do percentual de plantas duplas para as diferentes velocidades nos dois tratamentos. **Evidence of the percentage of double plants for the different speeds in the two treatments.**

Na Figura 6 é apresentado o gráfico relativo ao número de plantas aceitáveis entre os dois tratamentos nas quatro variáveis analisadas e novamente o sistema de acionamento por motores elétricos apresentou melhores resultados em relação ao acionamento mecânico. Para esta variável, o percentual foi de 13% favorável ao sistema de motores elétricos que não se diferenciou estatisticamente ao sistema mecânico apenas na variável de 6 km h<sup>-1</sup>.




FIGURA 6. Evidência do percentual de plantas aceitáveis para as diferentes velocidades nos dois tratamentos. **Evidence of the percentage of acceptable plants for the different speeds in the two treatments.**

Na Tabela 02, são apresentados os dados da análise estatística para os tratamentos C.C.C e S.C.C para as linhas interna (L.I), central (L.C) e externa (L.E).

TABELA 02. Resultado da análise estatística para avaliar o efeito da funcionalidade de compensação de curvas ativada em diferentes linhas da semeadora sobre a produtividade da cultura da soja. **Result of the statistical analysis to evaluate the effect of the turn compensation feature activated in different lines of the seeder on the productivity of the soybean crop.**

POPULAÇÃO DE PLANTAS (10m)					
Funcionalidade*	CV% (estatística)	Média Plantas - 10m	L.I	L.C	L.E
C.C.C	2,0%	117,6 a	117,7 aA	117,3 aA	117,7 aA
S.C.C		114,6 b	121,7 aA	116,7 aB	105,3 bC
PRODUTIVIDADE (kg ha <sup>-1</sup> )					
Funcionalidade*	CV% (estatística)	Média kg ha <sup>-1</sup>	L.I**	L.C**	L.E**
C.C.C	2,4%	1,642 a	1,635 aA	1,643 aA	1,648 aA
S.C.C		1,424 b	1,333 bB	1,405 bB	1,535 bA
*C.C.C – Com Compensação de Curvas; S.C.C – Sem Compensação de Curvas. **L.I – Linha Interna; L.C – Linha Central; L.E – Linha Externa. Médias seguidas das mesmas letras minúsculas nas colunas ou maiúsculas nas linhas não se diferem pelo teste de Tukey a 5%.					

De acordo com as evidências acima, a população de plantas se apresenta estável no tratamento C.C.C, isto é, 117,6 plantas em 10 metros lineares. Por outro lado, no tratamento S.C.C, a população em 10 metros lineares na L.I foi de 121,7, na L.C de 116,7 até 105,3 na L.E. Em relação a L.C, significou uma variação de população 4,3% superior na L.I e 9,8% inferior na L.E totalizando a variação de 14,1% entre uma extremidade e outra da semeadora na mesma condição de operação.

A semeadora operando com o recurso tecnológico C.C.C se diferencia significativamente da produtividade da mesma semeadora operando sem este recurso habilitado. Na média de produtividade, dentro da mesma passada da semeadora em uma linha curva, para a operação S.C.C houve um decréscimo de 202 kg ha<sup>-1</sup> na produtividade entre a L.I e a L.E.

Este comportamento se repetiu para todas as variáveis comparadas entre os tratamentos, ou seja, na L.I houve redução de 302 kg ha<sup>-1</sup>, na L.C redução de 238 kg ha<sup>-1</sup> e na L.E redução de 113 kg ha<sup>-1</sup>. Dentro do mesmo tratamento não foram registradas diferenças significativas, exceto para a variável L.E do tratamento S.C.C, que se diferiu das demais variáveis dentro deste mesmo tratamento.

Nota-se que a produtividade está associada em uma proporção inversa à população de plantas, ou seja, na condição do experimento, quanto maior a população, menor a produtividade evidenciada.

No Figura 7 é possível visualizar a variação significativa da população com o recurso S.C.C desabilitado. Por outro lado, quando o recurso C.C.C foi habilitado (FIGURA 8) há estabilidade da produtividade dentre as várias linhas de plantio da semeadora tendo reflexos diretos nos resultados de colheita.




FIGURA 7. Diferença de população entre as linhas interna (L.I), central (L.C) e externa (L.E) com a função de compensação de curvas ativada (C.C.C) em comparação à função desativada, isto é, sem compensação de curvas (S.C.C). **Population difference between inner (L.I), central (L.C) and outer (L.E) lines with curve compensation function enabled (C.C.C) compared to the function disabled, that is to say, without curve compensation (S.C.C).**




FIGURA 8. Diferença de produtividade entre as linhas interna (L.I), central (L.C) e externa (L.E) com a função de compensação de curvas ativada (C.C.C) em comparação à função desativada, isto é, sem compensação de curvas (S.C.C). **Productivity difference between inner (L.I), central (L.C) and outer (L.E) lines with curve**

**compensation function enabled (C.C.C) compared to the function disabled, that is to say, without curve compensation (S.C.C).**

Ao avaliar as variáveis analisadas pode-se verificar que em determinados pontos da lavoura ocorrem perdas, na média, em torno de 276,5 kg ha<sup>-1</sup> ou, se converter em “espécie”, tendo como base o preço atual (R\$ 180,00) da soja, os números giram em torno de R\$ 829,50 por hectare.

No contexto da Agricultura de Precisão, sistemas eficientes e com recursos para digitalização, como é o caso da automação da semeadora através de motores elétricos, apresentam ganhos significativos de produtividade e eliminação de variáveis que limitam o teto produtivo das culturas. Nesta pesquisa foram avaliadas apenas algumas funções disponíveis nestes sistemas, outros recursos devem ser avaliados também.

**CONCLUSÃO:** O resultado da pesquisa demonstrou efeito positivo do sistema de transmissão por motores elétricos em relação ao sistema de transmissão mecânica. O incremento da tecnologia melhorou a eficiência da semeadora, proporcionou recursos que agregaram recursos de Agricultura de Precisão, trouxe benefícios como a redução do CV% da população de plantas, redução do número de falhas, aumento de plantas dentro da distribuição aceitável, uniformidade da população em condições de curvas e o aumento da produtividade.

## REFERÊNCIAS

ABNT – ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **Semeadora de precisão:** ensaio de laboratório/método de ensaio, projeto de norma 04:015.06-004/1995. São Paulo: ABNT, 1996. 21 p.

BIULCHI, P. V. **Máquinas e mecanização agrícola.** Educacional S.A., Londrina, 2016. 236p. ISBN 978-85-8482-675-9.

CASÃO JUNIOR, R.; JOHANN, A. L.; DELALIBERA, H.C.; LADEIRA, A. de S.; SILVA, A. L. da; **AValiação da Qualidade de Semeadura de Soja no Paraná e Mato Grosso do Sul do Brasil.** IAPAR, 2019. Disponível em: <[http://www.agrisus.org.br/arquivos/artigo\\_Casao.pdf](http://www.agrisus.org.br/arquivos/artigo_Casao.pdf)> Acesso em: 26 jul. 2020.

CHMALZ, C. R. **VERIFICAÇÃO DE TIPOS DE DOSADORES DE SEMENTES DE MILHO E SOJA NO NORTE DO PARANÁ.** 2014. 28p. Dissertação (Mestrado em Agricultura de Precisão) – Programa de Pós-Graduação em Agricultura de Precisão, Universidade Federal de Santa Maria, Santa Maria. Disponível em: <<https://repositorio.ufsm.br/handle/1/4823>>. Acesso em: 18 jun. 2019.

DESBESSELL, D. M.; et al. A precisão na Distribuição plantas interfere no rendimento da soja? **Informativo Técnico.** Agrofarm. v2. n2. Cerejeiras, 2018. Disponível em: <<http://www.agricultura.gov.br/noticias/tecnologia>

-ja-e-usada-em-cerca-de-67-daspropriedades-rurais-do-pais-1>. Acesso em: 19 jun. 2019.

DORSEY, N. **How To Avoid Yield Loss Using Curve Compensation.** 2017. PrecisionAg. Disponível em: <<https://www.precisionag.com/market-watch/how-to-avoidyield-loss-using-curve-compensation/>>. Acesso em: 19 jun. 2019.

PICHINIM, N. R. M. A. **Qualidade de distribuição longitudinal de plantas de milho e sua produtividade:** um estudo de caso. 2012. 33p. Trabalho (Conclusão de Graduação). – Curso Tecnologia em Mecanização em Agricultura de Precisão, Faculdade de Tecnologia de Pompéia. Disponível em: <<https://repositorio.ufsm.br/>

handle/1/3611?show=full>. Acesso em: 18 jun. 2019.

# **5. Sensoriamento e amostragem**

# DIAGNÓSTICO DA FERTILIDADE DO SOLO VIA XRF: PRECISAMOS CONSIDERAR A PROFUNDIDADE E A ÁREA DA AMOSTRA NA MODELAGEM PREDITIVA?

Tiago Rodrigues Tavares<sup>1</sup>; Carlos Roberto Pinheiro Junior<sup>2</sup>; Elton Eduardo Novais Alves<sup>3</sup>; Rachel Ferraz de Camargo<sup>4</sup>; Hudson Wallace Pereira de Carvalho<sup>5</sup>

<sup>1</sup>Eng. Agrônomo, Pesquisador Pós-Doc - Laboratório de Instrumentação Nuclear, CENA, USP, Piracicaba-SP. tiagosrt@usp.br / (62) 9 8521-2188; <sup>2</sup>Eng. Agrônomo, Pesquisador Ph.D. - Departamento de Solos, UFRRJ, Seropédica-RJ; <sup>3</sup>Eng. Agrônomo, Pesquisador Pós-Doc - CESFRA, Mohammed VI Polytechnic University, BenGuerir, Marrocos; <sup>4</sup>Eng<sup>a</sup> de Alimentos, Mestranda - Laboratório de Instrumentação Nuclear, CENA, USP, Piracicaba-SP; <sup>5</sup>Químico, Professor - Laboratório de Instrumentação Nuclear, CENA, USP, Piracicaba-SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** A predição de atributos de fertilidade do solo usando espectrometria de fluorescência de raios X (XRF) depende da construção de bibliotecas espectrais robustas e modelos preditivos acurados. Neste contexto, ainda existe a necessidade de se definir estratégias de modelagem preditiva ótima que permita a generalização da replicação desses modelos. Assim, este trabalho objetivou avaliar o desempenho de modelos preditivos de atributos de fertilidade do solo ao se utilizar informações sobre a área e a profundidade das amostras como variáveis auxiliares aos dados do sensor XRF. Foram utilizadas 214 amostras de solo provenientes de cinco áreas agrícolas diferentes e coletadas em três profundidades distintas (0-20, 20-40 e 80-100 cm). Os modelos foram calibrados utilizando regressão linear múltipla. A inclusão da informação da área e da profundidade das amostras permitiu otimizar o desempenho preditivo para a determinação de argila e K extraível (ex-K). A predição de capacidade de troca catiônica (CTC) apresentou ganho de desempenho com a inclusão da variável área, por sua vez a inclusão da informação de profundidade deteriorou o desempenho preditivo de CTC ao compararmos com o modelo utilizando apenas dados do XRF. A predição de ex-Ca foi a única que não apresentou melhoria de desempenho com a inclusão dos dados auxiliares. Os melhores desempenhos foram obtidos com o cenário XRF + Área + Prof. para predição de argila (RPD = 6,2) e ex-K (RPD = 2,0), com o cenário XRF + Área para a predição de CTC (RPD = 3,4) e apenas com o XRF para ex-Ca (RPD = 3,3). Os resultados deste trabalho permitem inferir que a inclusão da profundidade e da área das amostras como variáveis auxiliares aos dados do XRF podem ser uma alternativa para otimizar o desempenho preditivo de modelos para atributos de fertilidade do solo, tendo observado uma redução do erro entre 0,5 e 19,8%. Contudo, essa avaliação deve ser específica para cada atributo, uma vez que perda de desempenho também podem ocorrer.

**PALAVRAS-CHAVE:** Sensoriamento próximo do solo; bibliotecas espectrais; sensores inteligentes

## SOIL FERTILITY DIAGNOSTICS VIA XRF: DO WE NEED TO CONSIDER SAMPLE DEPTH AND SITE IN PREDICTIVE MODELING?

**ABSTRACT:** Prediction of soil fertility attributes using X-ray fluorescence spectrometry (XRF) depends on the development of robust spectral libraries and accurate predictive modeling. In this context, there is still a need to define optimal predictive modeling strategies that allow a widespread extrapolation of these models. Thus, this work aimed to evaluate the performance of predictive models for soil fertility attributes when using information about the samples' area and depth as auxiliary variables to the XRF sensor data. A total of 214 soil samples from five different agricultural areas and collected at three different depths (0-20, 20-40, and 80-100 cm) were used. The models were calibrated using multiple linear regression. Including the area and depth information allowed the optimization of the model performance for predicting clay and extractable K (ex-K). The prediction of cation exchange capacity (CTC) showed a better performance with the inclusion of the area, while the inclusion of depth information deteriorated the predictive performance of CTC when compared to the model using only XRF data. The prediction of ex-Ca was the only one that did not show an improvement in performance with the inclusion of the auxiliary data. The best performances were obtained with the XRF + Area + Prof. scenario for clay (RPD = 6.2) and ex-K (RPD = 2.0), with the XRF + Area scenario for the CTC

prediction (RPD = 3.4) and only with the XRF for ex-Ca (RPD = 3.3). The results of this study allow us to infer that the inclusion of the sample depth and area as auxiliary variables to the XRF data can be an alternative to optimize the predictive performance of models for soil fertility attributes, having observed an error reduction ranging from 0.5 to 19.8%. However, this evaluation should be attribute-specific, since loss of performance can also occur.

**KEYWORDS:** Proximal soil sensing; spectral libraries; smart sensors

**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 e até de características físico-químicas via linhas de espalhamento Thomson e Compton (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), atributos químicos (e.g., saturação de bases, capacidade de troca catiônica (CTC), etc) (SILVA et al., 2017) e micronutrientes (ANDRADE et al., 2021). 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, apesar dos bons desempenhos relatados acima, casos de insucesso são comuns, inclusive sendo reportados em algumas publicações científicas, e.g., Teixeira et al. (2018) relataram modelos preditivos ruins para ex-K ( $0,04 \leq R^2 \leq 0,12$ ) usando amostras de solo adquiridas em áreas com diferentes usos do solo e, por sua vez, modelos de ex-P mostraram  $R^2$  entre 0,03 e 0,90 em pesquisas de diferentes autores (Teixeira et al., 2018; Lima et al., 2019; Tavares et al., 2020). Para que o XRF se torne uma realidade para análises rápidas e *easy-to-use* da fertilidade do solo é necessário ampliar o conhecimento sobre os fatores que influenciam o desempenho negativo de predições via XRF, de modo a estabelecer estratégias de modelagem preditiva robustas para compor a inteligência do sensor. Assim, é necessário buscar modelos preditivos generalistas que sejam capazes de considerar as particularidades locais de grupos de amostras. Uma forma simples de se fazer isso é utilizando informações categóricas das amostras, e.g., área e a profundidade que esta foi coletada. Ambos os fatores mencionados podem influenciar na composição físico-química das amostras (e.g., devido a diferentes mineralogias, em áreas diferentes, e diferentes características físico-químicas, em profundidades diferentes), influenciando no efeito físico e químico de matriz do solo e, conseqüentemente, no desempenho de predição da fertilidade via XRF (RAVANSARI et al., 2020; Rosin et al., 2022). Desta forma, o presente trabalho visa responder a seguinte pergunta: combinar dados do XRF com a informação da área das amostras e/ou sua profundidade de coleta permite a otimização de modelos preditivos de atributos de fertilidade do solo? Para isso, este trabalho verificou o desempenho de um modelo generalista usando dados de XRF em prever teores de argila, ex-Ca, ex-K e CTC em amostras de solo proveniente de cinco áreas agrícolas diferentes, as quais foram coletas em três profundidades distintas.

**MATERIAIS E MÉTODOS:** Foi utilizado um conjunto de 214 amostras de solo coletadas em cinco áreas agrícolas localizadas nos municípios de Monte Azul (Área G), Patrocínio Paulista (Área H), Coronel Macedo (Área I), Catanduva (Área J) e Torrinha (Área K), todos no estado de São Paulo. Compuseram o banco de dados um total de 6 amostras da área G, 45 da H, 50 da I, 87 da J e 26 da K. As amostras foram coletas em três profundidades distintas, de 0-20, 20-40 e 80-100 cm, totalizando respectivamente 157, 28 e 29 amostras em cada uma dessas profundidades. As variáveis dependentes (variáveis Y) argila, ex-K, ex-Ca e CTC foram determinadas por análises de rotina de fertilidade do solo, realizados em um laboratório comercial seguindo os métodos descritos por Van Raij et al. (2001). Em seguida, a contraprova das amostras foi analisada utilizando um equipamento portátil de XRF por energia dispersiva (ED-XRF) (Tracer III-SD, Bruker AXS, Madison, WI, EUA), com a condição de operação do tubo de raios X de 35kV de tensão e 7  $\mu$ A de corrente. Cada amostra foi irradiada por 30s, sem utilização de filtro e sob pressão atmosférica. Os espectros do XRF foram obtidos através do processo de deconvolução utilizando o programa Artax® (Bruker AXS, Madison, WI, EUA) e a intensidade em contagens por segundo (cps) foram obtidas para as linhas de emissão Al-K $\alpha$ , Si-K $\alpha$ , P-K $\alpha$ , S-K $\alpha$ , K-K $\alpha$ , Ca-K $\alpha$ , Ti-K $\alpha$ , Cr-K $\alpha$ , Mn-K $\alpha$ , Fe-K $\alpha$ , Ni-K $\alpha$ , Cu-K $\alpha$ , Zn-K $\alpha$  e Zr-K $\alpha$ , bem como para as linhas de espalhamento Thomson-K $\alpha$ , Thomson-L $\alpha$  e Compton-K $\alpha$  do Rh presente no anodo (Figura 1).






FIGURA 1. Espectros médios das áreas G, H, I, J e K mostrando o espectro inteiro e em detalhe as linhas de emissão entre 8 e 25 keV (A) e em detalhe as linhas de emissão entre 1 e 9 keV (B). **Mean spectra of areas G, H, I, J and K showing the entire spectrum and the snapshot of the emission lines between 8 and 25 keV (A) and the snapshot of the emission lines between 1 and 9 keV (B).**

Todas essas 17 variáveis do XRF foram utilizadas como variáveis explicativas na modelagem preditiva dos atributos de fertilidade. Além dessas variáveis explicativas, também foram utilizadas as variáveis categóricas de área e profundidade como variáveis independentes. Para isso, essas variáveis foram tratadas como dummies (SUITS, 1957), procedimento que cria variáveis binárias para cada categoria das variáveis qualitativas e que é utilizado para evitar ponderação arbitrária (FÁVERO; BELFIORE, 2017). Assim, este trabalho comparou quatro estratégias de modelagem preditiva, as quais utilizaram: (i) apenas dados do XRF; (ii) dados do XRF de forma combinada com a informação da área da amostra; (iii) dados do XRF de forma combinada com a informação da profundidade da amostra e (iv) dados do XRF de forma combinada com a informação da área e da profundidade da amostra. Os modelos preditivos foram calibrados e validados após divisão do conjunto de dados em dois subconjuntos contendo 70 (n = 150) e 30% (n = 64) das observações, procedimento realizado utilizando o algoritmo de Kennard-Stone (KENNARD; STONE, 1969) aplicado nas variáveis dependentes. A calibração foi realizada utilizando regressão linear múltipla (MLR) e a qualidade dos modelos foi avaliada pelo coeficiente de determinação ( $R^2$ ), raiz do erro quadrático médio (RMSE), razão do desempenho pela distância interquartil (RPIQ) (BELLON-MAUREL et al., 2010) e o desvio porcentual relativo (RPD) (CHANG et al., 2001). A interpretação dos valores de RPD foi realizada seguindo as seguintes classes de interpretação: modelos excelentes ( $RPD \geq 3,0$ ), modelos bons ( $3,0 > RPD \geq 2,0$ ), modelos razoáveis ( $2,0 > RPD \geq 1,4$ ) e modelos ruins ( $RPD < 1,4$ ). Também foi calculada a redução do erro (RE) para avaliação da redução em porcentagem do RMSE dos modelos utilizando apenas os dados do XRF com os demais. A criação de variáveis *dummies*, bem como a calibração e validação dos modelos foi realizada no software R (versão 4.1.2). Para a criação de *dummies*, utilizou-se o pacote fastDummies (KAPLAN, 2020).

**RESULTADOS E DISCUSSÃO:** É esperado que teores de argila se correlacionem com as linhas de emissão de Fe, Ti e Al, em função a presença destes elementos em minerais de argila (ANDRADE et al., 2020;

BENEDET et al., 2020), bem como que os teores de ex-Ca e CTC se correlacionem com a linha de emissão do Ca e teores de ex-K com a linha de emissão do K (LIMA et al., 2019; Teixeira et al., 2019; TAVARES et al., 2020). Embora essas relações tenham sido constantemente apresentadas na literatura, os dados do presente trabalho mostram que elas variam de intensidade em diferentes áreas e, em alguns casos, podem até não se apresentarem (Tabela 1). Por exemplo, as correlações de ex-Ca e linha Ca-K $\alpha$  tiveram correlação entre 0,71 e 0,86; correlações de CTC e Ca-K $\alpha$  oscilaram entre 0,43 e 0,74, apresentando uma correlação baixa ( $r = 0,27$ ) ao juntar todas as áreas; ainda mais contrastante, as correlações entre Ti-K $\alpha$  e argila apresentaram  $r \geq 0,80$  nas áreas H, I e K e correlação nula ( $r = 0$ ) na área J. Resultado semelhante também foi observado nas correlações em diferentes profundidades de solo (Tabela 2), e.g., o ex-Ca apresentou correlação variando entre 0,68 e 0,89 com o Ca-K $\alpha$  e a CTC entre 0,12 e 0,78 com esta mesma linha de emissão.

TABELA 1. Correlação de Pearson entre as linhas de emissão K $\alpha$  e de espalhamento do Rh (Compton K $\alpha$ , Thomson K $\alpha$  e L $\alpha$ ) do XRF e os atributos de fertilidade do solo para as amostras de cada área estudada e para todas as áreas juntas. **Pearson's correlation between XRF emission lines and soil fertility attributes for the samples of each studied area and for all areas together.**

Área	Al-K $\alpha$	Si-K $\alpha$	P-K $\alpha$	S-K $\alpha$	K-K $\alpha$	Ca-K $\alpha$	Ti-K $\alpha$	Cr-K $\alpha$	Mn-K $\alpha$	Fe-K $\alpha$	Ni-K $\alpha$	Cu-K $\alpha$	Zn-K $\alpha$	Zr-K $\alpha$	Thom-K $\alpha$	Thom-L $\alpha$	Com-K $\alpha$
Argila																	
G	0,66	-0,87	-0,35	0,54	-0,36	-0,47	0,49	-0,08	0,22	0,91	0,54	0,17	-0,83	-0,21	-0,27	0,10	-0,85
H	0,75	-0,92	0,47	0,08	-0,02	-0,01	0,86	-0,06	0,68	0,95	-0,90	0,34	0,03	0,47	-0,59	0,89	-0,95
I	0,44	-0,89	0,12	-0,01	-0,52	-0,06	0,80	0,68	0,51	0,93	-0,91	0,66	0,37	-0,79	-0,68	0,81	-0,90
J	0,57	-0,65	-0,29	-0,17	-0,31	-0,22	0,00	0,12	-0,40	0,46	-0,29	0,10	-0,17	0,23	-0,36	0,32	-0,37
K	0,40	-0,91	0,54	0,12	-0,53	0,28	0,84	-0,04	0,57	0,94	-0,88	0,80	0,65	0,12	-0,63	0,79	-0,90
Geral	0,62	-0,76	-0,03	-0,31	-0,13	-0,33	0,61	0,06	0,13	0,90	-0,85	0,80	0,67	0,48	-0,77	0,80	-0,91
ex-Ca																	
G	-0,11	0,44	0,19	-0,66	0,43	0,86	0,25	0,69	-0,16	-0,39	0,09	0,05	0,56	0,36	0,48	0,54	0,69
H	-0,03	-0,14	0,11	0,25	-0,09	0,86	0,05	0,17	0,21	0,15	-0,07	0,08	0,19	-0,10	-0,29	0,17	-0,15
I	0,28	-0,20	-0,08	-0,25	-0,02	0,85	0,04	0,18	0,10	0,19	-0,18	0,31	0,06	-0,20	-0,08	0,26	-0,16
J	-0,46	-0,01	0,57	-0,05	0,65	0,77	0,30	0,24	0,51	0,28	-0,31	-0,03	0,40	-0,08	-0,17	0,26	-0,51
K	0,34	-0,73	0,24	0,09	-0,25	0,79	0,58	-0,11	0,52	0,67	-0,66	0,56	0,57	-0,11	-0,51	0,60	-0,63
Geral	0,02	-0,20	0,44	-0,10	0,58	0,71	0,10	0,36	0,33	0,13	-0,10	0,10	0,29	0,09	-0,19	0,16	-0,21
ex-K																	
G	-0,46	0,62	0,82	0,21	0,06	-0,16	-0,51	-0,07	-0,22	-0,48	-0,60	-0,08	0,68	0,35	0,28	-0,57	0,40
H	0,52	-0,61	0,37	0,20	0,25	0,05	0,61	-0,05	0,47	0,60	-0,51	0,42	-0,17	0,42	-0,32	0,58	-0,53
I	0,35	-0,29	-0,21	-0,22	-0,03	0,48	0,17	0,17	0,20	0,32	-0,32	0,34	0,20	-0,38	-0,20	0,34	-0,29
J	-0,08	0,06	0,21	0,18	0,24	0,32	0,03	0,02	0,05	-0,08	0,11	0,12	0,28	-0,06	-0,04	0,03	-0,01
K	-0,07	0,23	0,16	-0,01	0,38	0,07	-0,35	-0,37	-0,40	-0,29	0,39	-0,25	-0,08	-0,35	0,27	-0,33	0,34
Geral	0,36	-0,40	0,16	-0,16	0,31	0,11	0,23	0,32	0,19	0,32	-0,29	0,34	0,51	0,36	-0,33	0,31	-0,37
CTC																	
G	-0,33	0,53	-0,02	-0,60	0,21	0,74	0,18	0,61	-0,38	-0,53	0,10	0,17	0,52	0,35	0,34	0,48	0,68
H	0,36	-0,57	0,31	0,21	-0,11	0,60	0,46	0,13	0,50	0,55	-0,49	0,22	0,17	0,15	-0,52	0,54	-0,56
I	0,44	-0,53	0,15	0,15	-0,30	0,43	0,36	0,42	0,22	0,55	-0,51	0,48	0,24	-0,47	-0,39	0,60	-0,49
J	-0,44	-0,05	0,62	-0,04	0,73	0,61	0,33	0,21	0,46	0,34	-0,33	0,00	0,40	-0,05	-0,19	0,27	-0,60
K	0,32	-0,87	0,50	0,13	-0,47	0,47	0,81	-0,11	0,57	0,91	-0,84	0,80	0,72	0,00	-0,66	0,77	-0,87
Geral	0,30	-0,54	0,41	-0,20	0,45	0,27	0,42	0,27	0,34	0,58	-0,54	0,50	0,61	0,36	-0,54	0,55	-0,65

Correlações positivas foram apresentadas em escala de azul e negativas em escala de vermelho, de modo a destacar os valores com correlações mais fortes.

É conhecido que a correlação entre os dados de XRF e atributos de fertilidade é dependente do intervalo dos valores desses atributos em cada área, i.e., ao comparar variáveis que se correlacionam, quanto maior a amplitude (intervalo entre menor e maior valor), maior será o coeficiente de correlação (Adamchuk et. al, 2004). Contudo, outros dois fatores também podem contribuir na mudança dessa correlação ao observar diferentes áreas e profundidades, são eles: (i) o efeito matriz das amostras nos dados do XRF, ou seja, solos provindos de matrizes muito distintas (e.g., alto e baixo teor de Fe) podem apresentar intensidades diferentes de emissão de fluorescência, em função de diferenças na composição mineralógica, mesmo que as amostras possuam o mesmo teor trocável do atributo de fertilidade (efeito de reforço e absorção da matriz) (LU et al., 2022); e (ii) com mudanças na relação entre cada atributo de fertilidade e os teores totais dos elementos no solo, em função, por exemplo, da aplicação recente de calcário e/ou fertilizantes de baixa solubilidade (pó de rocha), resultando em diferentes relações entre teores totais e trocáveis de um determinado elemento em diferentes áreas agrícolas e/ou profundidade de solo. Neste sentido, ao considerar a informação da área e da profundidade como variáveis auxiliares aos dados XRF é possível que parte dessa interferência seja mitigada, otimizando o desempenho dos modelos preditivos.



TABELA 2. Correlação de Pearson entre as linhas de emissão  $K\alpha$  e de espalhamento do Rh (Compton  $K\alpha$ , Thomson  $K\alpha$  e  $L\alpha$ ) do XRF e os atributos de fertilidade do solo para as amostras coletadas nas diferentes profundidades estudadas e para todas as amostras juntas. **Pearson's correlation between XRF emission lines and soil fertility attributes for the samples collected at the different studied depths and for all samples together.**

Prof. (cm)	Al-K $\alpha$	Si-K $\alpha$	P-K $\alpha$	S-K $\alpha$	K-K $\alpha$	Ca-K $\alpha$	Ti-K $\alpha$	Cr-K $\alpha$	Mn-K $\alpha$	Fe-K $\alpha$	Ni-K $\alpha$	Cu-K $\alpha$	Zn-K $\alpha$	Zr-K $\alpha$	Thom-K $\alpha$	Thom-L $\alpha$	Com-K $\alpha$
Argila																	
0-20	0,69	-0,79	0,01	-0,34	-0,12	-0,36	0,64	0,10	0,19	0,91	-0,87	0,83	0,71	0,53	-0,79	0,82	-0,92
20-40	0,63	-0,74	-0,19	-0,23	-0,23	0,07	0,24	0,23	-0,28	0,53	-0,28	0,15	0,04	0,30	-0,46	0,53	-0,34
80-100	0,56	-0,64	-0,44	-0,12	-0,45	-0,32	-0,05	0,23	-0,44	0,53	-0,38	0,63	-0,27	0,17	-0,24	0,31	-0,27
Geral	0,62	-0,20	0,16	-0,20	0,04	0,63	0,37	-0,05	0,43	0,21	0,37	0,42	-0,62	0,02	0,26	-0,08	0,26
ex-Ca																	
0-20	0,18	-0,23	0,30	-0,08	0,45	0,68	0,08	0,38	0,21	0,17	-0,13	0,21	0,32	0,08	-0,25	0,20	-0,21
20-40	-0,41	-0,03	0,63	-0,05	0,76	0,89	0,43	0,34	0,59	0,33	-0,30	-0,18	0,25	0,02	-0,06	0,28	-0,63
80-100	-0,60	0,15	0,65	-0,13	0,68	0,80	0,20	0,12	0,53	0,08	-0,25	-0,03	0,46	-0,13	-0,10	0,09	-0,46
Geral	0,02	-0,40	0,41	0,33	-0,03	-0,11	-0,07	0,43	0,02	-0,33	-0,54	-0,61	0,14	-0,31	0,01	-0,16	-0,83
ex-K																	
0-20	0,51	-0,48	0,03	-0,27	0,33	0,02	0,25	0,46	0,20	0,36	-0,34	0,39	0,55	0,46	-0,37	0,34	-0,40
20-40	-0,01	-0,09	0,39	0,23	0,38	0,43	0,13	0,26	-0,01	0,08	0,07	0,24	0,16	-0,14	-0,15	0,16	-0,21
80-100	-0,29	0,17	0,49	0,23	0,60	0,42	0,02	0,01	0,28	-0,09	-0,09	-0,16	0,25	-0,21	0,00	0,04	-0,29
Geral	0,36	-0,54	-0,01	0,20	-0,43	0,24	0,22	-0,05	0,15	0,56	0,82	0,07	-0,24	0,20	0,18	0,87	-0,11
CTC																	
0-20	0,59	-0,68	0,26	-0,24	0,27	0,12	0,47	0,34	0,28	0,69	-0,64	0,65	0,70	0,47	-0,67	0,66	-0,73
20-40	-0,38	-0,09	0,66	-0,08	0,77	0,78	0,48	0,43	0,51	0,41	-0,32	-0,09	0,34	0,05	-0,14	0,31	-0,72
80-100	-0,56	0,12	0,68	-0,20	0,86	0,59	0,21	0,02	0,50	0,13	-0,24	-0,05	0,44	-0,19	-0,02	0,07	-0,56
Geral	0,30	0,76	0,01	0,16	-0,06	0,56	0,13	0,32	0,10	-0,83	-0,09	-0,17	0,13	-0,27	-0,66	0,08	-0,39

Correlações positivas foram apresentadas em escala de azul e negativas em escala de vermelho, de modo a destacar os valores com correlações mais fortes.

Os modelos preditivos avaliados neste trabalho foram calibrados e validados em conjuntos de amostras com amplitude e variação semelhantes (Figura 2) e o desempenho desses modelos estão apresentados na Tabela 3. Todos os modelos de argila, ex-Ca e CTC apresentaram desempenho de predição excelente, com  $RPD \geq 3,0$ . Por sua vez, os modelos de ex-K apresentaram desempenho oscilando entre razoável e bom ( $1,8 \leq RPD \leq 2,0$ ).




FIGURA 2. Gráficos Boxplot dos conjuntos de calibração (em azul) e validação (em laranja) dos atributos de fertilidade estudados. **Boxplot graphs of the calibration (in blue) and validation (in orange) sets for the studied soil fertility attributes.**

A utilização da informação de área como dados auxiliares aos do XRF aumentaram o desempenho dos modelos para a predição de argila, ex-K e CTC em comparação ao modelo utilizando apenas os dados do XRF (Tabela 3). Essa otimização foi maior para a argila ( $RE = 18,3\%$ ), seguida do modelo de ex-K ( $RE = 4,4\%$ ) e do de CTC ( $RE = 2,8\%$ ). O modelo de ex-Ca perdeu desempenho ao incluir a informação de área no modelo preditivo ( $RE = -2,9\%$ ). A inclusão da informação sobre profundidade nos modelos preditivos permitiu uma melhoria mais expressiva apenas para o modelo de ex-K ( $RE = 7,4\%$ ), o modelo de argila apresentou melhoria sutil do desempenho ( $RE = 0,5\%$ ), o modelo de ex-Ca foi semelhante ao modelo utilizando apenas dados do XRF ( $RE = 0,0\%$ ) e o modelo de CTC apresentando degradação do desempenho ( $RE = -3,0\%$ ). Por sua vez, a utilização

de profundidade e área, ambos de forma combinada aos dados espectrais, permitiu ganhos de desempenho mais expressivos para predição de argila e ex-K (RE de 19,8% para argila e de 12,1 para ex-K).

TABELA 3. Desempenho dos modelos preditivos de argila, ex-Ca, ex-K e CTC via regressão linear múltipla utilizando (i) apenas os dados do XRF, (ii) dados do XRF combinados com a “dummização” da variável área (XRF + Área), (iii) dados do XRF combinados com a “dummização” da variável profundidade (XRF + Prof.) e (iv) dados do XRF combinados com a “dummização” da variável área e profundidade (XRF + Área + Prof.).  
**Performance of predictive models for clay, ex-Ca, ex-K and CEC via multiple linear regression using (i) XRF data only, (ii) XRF data combined with the dummization of area (XRF + Área), (iii) XRF data combined with the dummization of depth (XRF + Prof.), and (iv) XRF data combined with the dummization of area and depth (XRF + Área + Prof.).**

	Calibração					Validação				
	R <sup>2</sup>	RMSE	RE%	RPD	RPIQ	R <sup>2</sup>	RMSE	RE*	RPD	RPIQ
Argila										
XRF	0,95	26,73		5,5	5,3	0,93	33,49		4,9	7,6
XRF + Área	0,96	22,39	16,2%	6,6	6,4	0,96	27,37	18,3%	6,0	9,3
XRF + Prof.	0,95	25,99	2,8%	5,7	5,5	0,93	33,31	0,5%	5,0	7,6
XRF + Área + Prof.	0,96	21,69	18,8%	6,8	6,6	0,96	26,86	19,8%	6,2	9,4
ex-Ca										
XRF	0,83	2,90		3,0	3,8	0,84	3,40		3,3	3,0
XRF + Área	0,84	2,82	2,5%	3,1	3,9	0,83	3,50	-2,9%	3,2	2,9
XRF + Prof.	0,83	2,90	0,0%	3,0	3,8	0,84	3,40	0,1%	3,3	3,0
XRF + Área + Prof.	0,84	2,82	2,7%	3,1	3,9	0,84	3,48	-2,6%	3,2	2,9
ex-K										
XRF	0,43	0,64		2,2	3,0	0,31	0,96		1,8	2,3
XRF + Área	0,48	0,60	5,9%	2,3	3,2	0,34	0,91	4,4%	1,9	2,4
XRF + Prof.	0,49	0,62	2,6%	2,2	3,1	0,37	0,89	7,4%	1,9	2,5
XRF + Área + Prof.	0,54	0,58	9,8%	2,4	3,4	0,41	0,84	12,1%	2,0	2,6
CTC										
XRF	0,82	5,29		3,0	3,7	0,83	5,97		3,3	4,9
XRF + Área	0,83	5,00	5,5%	3,2	4,0	0,84	5,81	2,8%	3,4	5,0
XRF + Prof.	0,82	5,23	1,2%	3,1	3,8	0,83	6,15	-3,0%	3,2	4,8
XRF + Área + Prof.	0,84	4,99	5,8%	3,2	4,0	0,83	5,92	0,8%	3,3	4,9

\*Valores negativos de RE indicam que o modelo aumentou o erro em relação ao modelo utilizando apenas dados do XRF; Os valores de RPD e RPIQ foram apresentados em escala de verde, destacando os valores mais altos para cada atributo.

Em suma, os melhores desempenhos foram obtidos com o cenário XRF + Área + Prof. para predição de argila (RPD = 6,2) e ex-K (RPD = 2,0) e com o cenário XRF + Área para a predição de CTC (RPD = 3,4). A predição de ex-Ca apresentou desempenhos semelhantes (RPD = 3,3) tanto com o cenário usando apenas os dados do XRF, quanto com o cenário XRF + Prof., sendo o único atributo que não apresentou melhoria de desempenho com a inclusão dos dados auxiliares avaliados neste trabalho. A inclusão da informação sobre a área da amostra permitiu aumento de desempenho mais expressivos que a inclusão das informações de profundidade. Os resultados deste trabalho permitem inferir que a inclusão da profundidade e da área das amostras como variáveis auxiliares aos dados do XRF podem ser uma alternativa para otimizar o desempenho preditivo de modelos, contudo essa avaliação deve ser específica para cada atributo, uma vez que perda de desempenho podem ocorrer. Gráficos de dispersão relacionando os valores preditos e medidos (do conjunto de validação) dos modelos de melhores desempenho estão apresentados na Figura 3. Observa-se que amostras com altos teores de ex-K não se adequaram ao modelo calibrado uma vez que se posicionaram longe da reta 1:1, indicando um alto erro de predição (Figura 3C). Assim, embora a inclusão das informações de área e profundidade tenham permitido otimizar a modelagem preditiva de argila, ex-K e CTC, a presença de amostras que não se adequaram ao modelo calibrado para ex-K indica que outras variáveis auxiliares deverão ser incluídas para a generalização do modelo. Neste sentido, outras técnicas, que permitem análise direta de sólidos, devem ser avaliadas e empregadas, e.g., espectroscopia vis-NIR, sensores de susceptibilidade magnética, entre outros. Também é válido mencionar que outras estratégias de modelagem preditiva mais complexas, tal como modelagem multinível e/ou modelos computacionais (e.g., redes neurais artificiais,

florestas randômicas), podem ser alternativas para promoverem ganhos de desempenho e devem ser consideradas em trabalhos futuros.

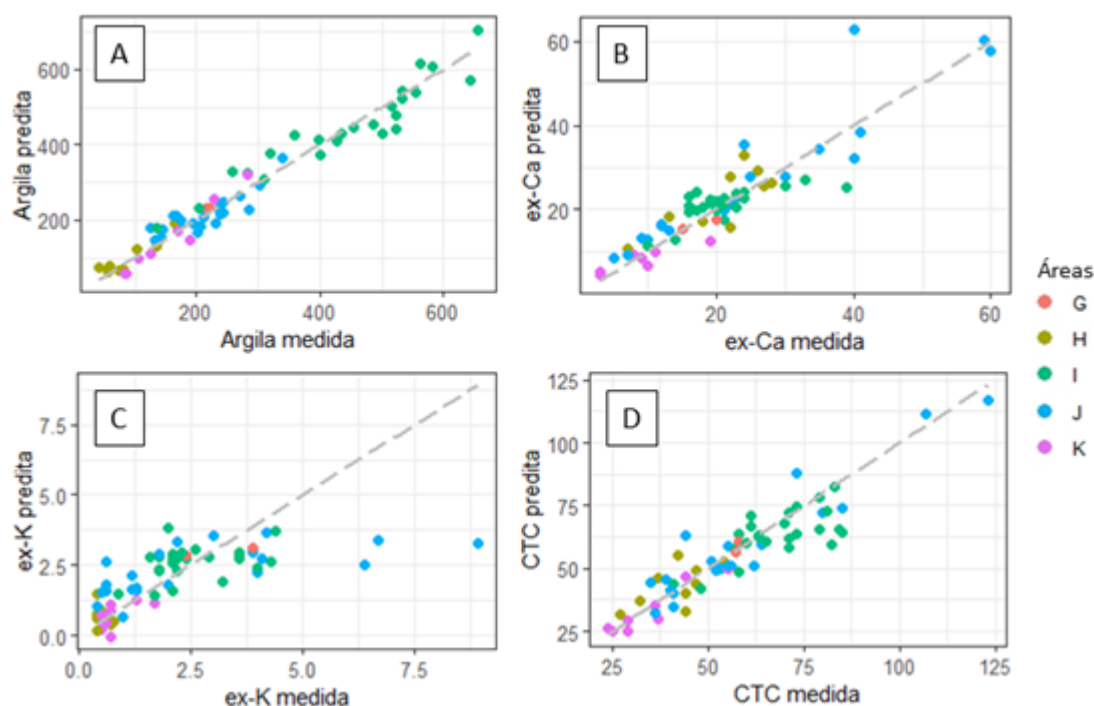


FIGURA 3. Gráficos de dispersão (para o conjunto de validação,  $n = 64$ ) relacionando os valores preditos e medidos de argila (A), Ca extraível (ex-Ca; B), K extraível (ex-K; C) e capacidade de troca catiônica (D), os quais foram obtidos pelos melhores modelos de regressão linear múltipla indicados na Tabela 3 (predição de argila e ex-K utilizaram dados do XRF combinados com informação da área e da profundidade; predição de ex-Ca utilizou apenas a informação do XRF; predição de CTC utilizou dados do XRF combinados com informação da área). A CTC, ex-Ca e ex-K foram expressos em  $\text{mmol}_c \text{dm}^{-3}$  e a argila em  $\text{mg kg}^{-1}$ . **Scatter plots (for the validation set,  $n = 64$ ) of measured versus predicted clay (A), exchangeable (ex-) Ca (B), ex-K (C), and cation exchange capacity (D), which were obtained by the best multiple linear regression models shown in Table 3 (clay and ex-K prediction used XRF data combined with sample area and depth information; ex-Ca prediction used only XRF information; CTC prediction used XRF data combined with the information of sample area). CTC, ex-Ca, and ex-K were expressed in  $\text{mmol}_c \text{dm}^{-3}$  and clay in  $\text{mg kg}^{-1}$**

**CONCLUSÃO:** Tanto a utilização da informação sobre a área, quanto sobre a profundidade da amostra, permitiu ganhos de desempenho para a predição de argila e K extraível (ex-K). A predição da capacidade de troca catiônica (CTC) apresentou ganho de desempenho com a inclusão da área como variável auxiliar, por sua vez a inclusão da informação de profundidade deteriorou seu desempenho preditivo ao compararmos com o modelo utilizando apenas dados do XRF. A predição de ex-Ca foi a única que não apresentou melhoria de desempenho com a inclusão dos dados auxiliares (área e profundidade). Os melhores desempenhos foram obtidos com o cenário XRF + Área + Prof. para predição de argila ( $\text{RPD} = 6,2$ ) e ex-K ( $\text{RPD} = 2,0$ ), com o cenário XRF + Área para a predição de CTC ( $\text{RPD} = 3,4$ ) e apenas com o XRF para ex-Ca ( $\text{RPD} = 3,3$ ). Os resultados deste trabalho permitem inferir que a inclusão da informação da profundidade e da área das amostras como variáveis auxiliares aos dados do XRF melhoram o desempenho preditivo de modelos para parte dos atributos de fertilidade do solo, com redução do erro entre 0,5 e 19,8%. Contudo, a utilização dessas variáveis auxiliares nos modelos deve ser avaliada para cada atributo de fertilidade no momento da definição de modelos de calibração, uma vez que também foi observada perda de desempenho na estimativa do ex-Ca e CTC.

**AGRADECIMENTOS:**

Agradecemos à empresa Ribersolo Laboratório de Análises Agrícolas, pela disponibilização das amostras e análises de referência, bem como à FAPESP pelo suporte financeiro ao T.R.T. (processo nº 2020/16670-9).

## REFERÊNCIAS

- Adamchuk, V.I.; Hummel, J.W.; Morgan, M.T.; Upadhyaya, S.K. On-the-go soil sensors for precision agriculture. **Computers and Electronics in Agriculture**, v.44, n.1, p.71-91, 2004.
- 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, p.113960, 2020.
- Andrade, R.; Silva, S.H.G.; Weindorf, D.C.; Chakraborty, S.; Faria, W.M.; Guilherme, L.R.G.; Curi, N. Micronutrients prediction via pXRF spectrometry in Brazil: Influence of weathering degree. **Geoderma Regional**, v.27, p.e00431, 2021.
- 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.
- Benedet, L.; Faria, W.M.; Silva, S.H.G.; Mancini, M.; Demattê, J.A.M.; Guilherme, L.R.G.; Curi, N. Soil texture prediction using portable X-ray fluorescence spectrometry and visible near-infrared diffuse reflectance spectroscopy. **Geoderma**, v.376, p.114553, 2020.
- 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, n.2, p.480-490, 2001.
- Fávero, L.P.; Belfiore P. Manual de análise de dados: estatística e modelagem multivariada com Excel®, SPSS® e Stata®. Elsevier Brasil, 2017.
- Kaplan, J. fastDummies: Fast Creation of Dummy (Binary). Columns and Rows from Categorical Variables. R package version 1.6, 2, 2020. Disponível online em: <<https://CRAN.R-project.org/package=fastDummies>>.
- Kennard, R.W.; Stone, L.A. computer aided design of experiments. **technometrics**, v.11, n.1, p.137-148, 1969.
- Lima, T.M. et al. Elemental analysis of Cerrado agricultural soils via portable x-ray fluorescence spectrometry: inferences for soil fertility assessment. **Geoderma**, v.353, p.264–272, 2019.
- Lu, J.; Guo, J.; Wei, Q.; Tang, X.; Lan, T.; Hou, Y.; Zhao, X. A matrix effect correction method for portable x-ray fluorescence data. **applied sciences**, v.12, n.2, p.568, 2022.
- 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. et al. Can spectral analyses improve measurement of key soil fertility parameters with x-ray fluorescence spectrometry? **Geoderma**, v.350, p.29-39, 2019.
- Ravansari, R.; Wilson, S.C.; Tighe, M. portable x-ray fluorescence for environmental assessment of soils: not just a point and shoot method. **Environment International**, v.134, p.105250, 2020.
- Rosin, N.A.; Demattê, J.A.; Leite, M.C.A.; Carvalho, H.W.P.; Costa, A.C.; Greschuk, L.T.; Curi, N.; Silva, S.H.G. The fundamental of the effects of water, organic matter, and iron forms on the pXRF information in soil analyses. **Catena**, 210, p.105868, 2022.

Silva, S.H.G.; Teixeira, A.F.D.S.; Menezes, M.D.D.; Guilherme, L.R.G.; Moreira, F.M.D.S.; Curi, N. Multiple linear regression and random forest to predict and map soil properties using data from portable x-ray fluorescence spectrometer (pXRF). **Ciência e Agrotecnologia**, v.41, n.6, p.648-664, 2017.

Suits, D.B. Use of dummy variables in regression equations. **Journal of the American Statistical Association**, v.52, n.280, p.548-551, 1957.

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.

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. **Ciência e Agrotecnologia**, v.42, n.5, p.501-512, 2018.

Van Raij, B.; Andrade, J.C.; Cantarela, H.; Quaggio, J.A. Análise química para avaliação de solos tropicais. iac: Campinas, Brasil, 2001. 285p.

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.

# GERAÇÃO DE ZONAS DE MANEJO EM POMARES DE MACIEIRAS COM BASE EM NDVI E PRODUTIVIDADE: UMA ANÁLISE EXPLORATÓRIA

Luciano Gebler<sup>1</sup>; Renata Bulling Magro<sup>2</sup>; Andrea de Rossi<sup>1</sup>; Eduardo Antonio Speranza<sup>3</sup>; Marcio da Silva Santos<sup>4</sup>

<sup>1</sup>Eng. Agrônomo, Pesquisador - Embrapa Uva e Vinho, Vacaria, RS. luciano.gebler@embrapa.br / (54) 9 9127-9398; <sup>2</sup>Eng° Ambiental e Sanitarista, Bolsista DTI - Embrapa Uva e Vinho, Vacaria, RS; <sup>3</sup>Bacharel em Ciência da Computação, Analista - Embrapa Agricultura Digital, Campinas, SP; <sup>4</sup>Eng. Agrônomo, Pesquisador - Agriexata, Vacaria, RS

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Índices de vegetação, como o Índice de Vegetação por Diferença Normalizada (NDVI), configuram ferramentas úteis para a geração de informações rápidas e precisas sobre as condições vegetativas de pomares, podendo contribuir para o aumento da produtividade. Neste trabalho, avaliou-se de maneira exploratória a aplicabilidade do NDVI para classificação de padrões temporais de velocidade de crescimento vegetativo de pomares de macieira, a fim de identificar os períodos capazes de fornecer dados mais relevantes a respeito do vigor do pomar e favorecer a definição de zonas de manejo. A área experimental corresponde a dois pomares de macieira da cultivar Gala, localizados na Embrapa em Vacaria (RS). Utilizou-se um sensor proximal para obtenção do NDVI a campo e gerando os mapas interpolados a seguir, calculando-se posteriormente a taxa de crescimento vegetativo. Realizou-se uma análise prospectiva para definição de zonas de manejo a partir do NDVI, considerando a produtividade como variável alvo. Os resultados preliminares sugerem ser possível identificar os períodos temporais mais relevantes para a aquisição de dados objetivando o manejo da produtividade. Assim, espera-se contribuir com um método de baixo custo e relativamente pouco dispendioso para a definição de zonas de manejo no pomar, visando aumento da produtividade.

**PALAVRAS-CHAVE:** Sensoriamento proximal; Fruticultura de precisão; Mapas de vigor

## GENERATION OF MANAGEMENT ZONES IN APPLE ORCHARDS BASED ON NDVI AND PRODUCTIVITY: AN EXPLORATORY ANALYSIS

**ABSTRACT:** Vegetation indices, such as the Normalized Difference Vegetation Index (NDVI), are useful tools for generating fast and accurate information on the vegetative conditions of orchards which can contribute to increased productivity. In this paper, applicability of the NDVI was evaluated in an exploratory way for classifying temporal patterns of vegetative growth velocity in apple orchards, in order to identify the periods capable of providing the most relevant data regarding the vigor of the orchard and favoring the definition of management zones. The experimental area corresponds to two apple orchards of the cultivar Gala, located at Embrapa in Vacaria (RS). A proximal sensor was used to obtain the NDVI in the field, generating the following interpolated maps, subsequently calculating the rate of vegetative growth. A prospective analysis was carried out to define management zones based on the NDVI, considering productivity as the target variable. Preliminary results suggest that it is possible to identify the most relevant time periods for the acquisition of data aimed at managing productivity. Thus, it is expected to contribute with a low-cost and relatively inexpensive method for the definition of management zones in the orchard, aiming at increasing productivity.

**KEYWORDS:** Proximal sensing; Precision fruit growing; vigor maps

**INTRODUÇÃO:** A agricultura de precisão (AP) está diretamente relacionada à obtenção mais rápida e eficiente de informações sobre a variabilidade de parâmetros agrônômicos durante as diferentes fases de crescimento vegetativo, no sentido de auxiliar a gestão ambiental da área e a tomada de decisão por parte dos produtores (Sinha et al, 2021). Os atuais esforços de investigação com relação à variabilidade temporal e espacial da produção de espécies frutíferas perenes contribuem para um crescente interesse em técnicas de sensoriamento remoto, principalmente para estimar variáveis biofísicas de áreas produtivas, tais como forma



e tamanho do dossel das plantas, indicadores de qualidade, rendimento e vigor (HALL et al, 2003; SANTOS; GEBLER; SEBEM, 2022; ZARCO-TEJADA et al, 2022).

A partir de imagens obtidas por sensoriamento remoto pode-se gerar os índices de vegetação (IVs), que são transformações lineares da reflectância do dossel e utilizam faixas do espectro eletromagnético relacionadas às características vegetativas. Entre os IVs, o Índice de Vegetação por Diferença Normalizada (NDVI) vem sendo utilizado desde os anos 1970 para monitoramento de biomassa (ROUSE et al., 1974; GAMON et al., 1995), pois é um indicador sensível à quantidade e a condição da vegetação, cujos valores variam no intervalo de -1 a 1. O NDVI está diretamente relacionado aos marcadores biofísicos de rendimento e de crescimento das culturas (ASNER, 1998) e possui aplicações diretas para o monitoramento de perfis sazonais e temporais da atividade fotossintética de diferentes cultivos agrícolas.

Os perfis temporais de NDVI podem ser utilizados para análise de variações fisiológicas, duração de períodos de senescência e de crescimento (PONZONI et al, 2012). Na produção de *Vitis vinifera* L., o NDVI vem sendo utilizado para a avaliação de crescimento de biomassa e classificação de vigor (VÉLEZ et al, 2022; BONILLA et al., 2015; OLDONI et al, 2019). Inclusive, é considerado como um indicador indireto de quantidade e qualidade da produção de vinhas (CANCELA et al., 2017; HALL et al., 2010). No entanto, para outras culturas perenes, por exemplo, a macieira (*Malus domestica* B.), o uso do NDVI como uma ferramenta para quantificação e caracterização temporal do crescimento vegetativo carece de mais análises.

Este é um estudo prospectivo com o objetivo de determinar a viabilidade de utilização do NDVI para quantificar as variações anuais de crescimento de macieira da cultivar Gala, conjuntamente como uma evidência do impacto da temporalidade do vigor do pomar na produtividade, buscando identificar períodos mais relevantes capazes de fornecer dados para posterior caracterização de zonas de manejo.

## MATERIAIS E MÉTODOS: Área de estudo

A área experimental corresponde a dois pomares de macieira, nomeados Fitotecnia e Gestão, que contêm a cultivar Gala com 11 anos de idade, localizados na Estação Experimental de Fruticultura de Clima Temperado da Empresa Brasileira de Pesquisa Agropecuária – Embrapa Uva e Vinho (28°30'58.2"S, 50°52'52.2"W) no município de Vacaria - RS.

O clima na região é considerado Cfb, do tipo subtropical úmido de acordo com a classificação de Köppen (PEEL et al, 2007). A característica do clima é de verões amenos e invernos frios, com média de temperatura máxima de 25°C e de temperatura mínima de 15°C. A precipitação ocorre de forma bem distribuída ao longo do ano, com média de 1.400 mm/ano, de acordo com dados da estação meteorológica do Inmet.

## Obtenção do NDVI por sensor proximal

Para obtenção das respostas espectrais da cultura, foram realizadas leituras de NDVI com o sensor óptico ativo FLEXUM, de fabricação da empresa brasileira Falker. O sensor possui resolução de 50 cm e realiza uma leitura por segundo de forma contínua, isso garante a produção de mapas de pontos de alta densidade.

As leituras com o sensor foram realizadas dias após a superação da dormência (DASD) das plantas de ambos os pomares (Fitotecnia e Gestão), em intervalos semanais ou quinzenais aproximadamente, totalizando 7 leituras. As leituras de NDVI do ano de 2020 iniciaram no dia 15 de setembro e finalizaram no dia 27 de outubro. Para 2021, realizamos leituras entre os dias 13 de setembro e 29 de novembro, resultando em cerca de um mês a mais de dados. No entanto, observou-se pouca variação dos valores de NDVI a partir do início de novembro (dados não apresentados); dessa forma, optou-se por apresentar, para ambos os pomares, a evolução do NDVI nos períodos de leituras concomitantes para 2020 e 2021 (Tabela 1).

TABELA 1. Datas de leitura de NDVI em 2020 e 2021. NDVI measurement dates in 2020 and 2021.

Leitura N#	Ano 2020		Ano 2021	
	dd/mm	DASD*	dd/mm	DASD*

01	15/09	17	13/09	16
02	22/09	24	22/09	25
03	29/09	31	29/09	32
04	06/10	38	07/10	40
05	14/10	46	19/10	52
06	21/10	53	26/10	59
07	27/10	59	03/11	66

\*DASD= dias após a superação da dormência das plantas.

### Processamento dos dados

O processamento dos dados foi realizado no software Qgis 3.16. A primeira etapa do processamento consistiu em uma análise exploratória com a finalidade de identificar valores anômalos (outliers) de NDVI. Para remoção destes, realizou-se a limpeza e filtragem dos dados por análise estatística (Boxplot) e análise da distribuição espacial dos pontos - verificação dos valores em relação à sua vizinhança.

Para geração de mapas do tipo raster, contendo as informações de NDVI para a totalidade das áreas de interesse, os dados foram interpolados a partir do método do inverso de potência das distâncias, utilizando parâmetro de potência 2 (IDW<sup>2</sup>).

### Obtenção da taxa de crescimento vegetativo (TCV)

A partir da série temporal de mapas de NDVI interpolado, calculou-se a derivada pela álgebra de mapas no SIG (Equação 1) para cada um dos pomares avaliados. O cálculo da derivada permitiu a obtenção da taxa de variação de crescimento vegetativo (TCV) ao longo do tempo.

$$TCV = \frac{(L_i - L_{i-1})}{\Delta t} \quad (1)$$

$TCV = \frac{(L_i - L_{i-1})}{\Delta t}$  = Taxa de crescimento vegetativo (adimensional);  $L_i = \frac{L_i}{i}$  = Mapa NDVI da leitura atual;  $L_{i-1} = \frac{L_{i-1}}{i-1}$  = Mapa NDVI da leitura anterior;  $\Delta t = \frac{t_i - t_{i-1}}{i - i - 1}$  = Intervalo de tempo entre as leituras.

Em seguida, para elaboração dos mapas temáticos, realizou-se a reclassificação dos mapas da TCV em 5 classes. Para fins de comparação temporal da TCV, definiu-se classes com base na TCV do ano de 2020, sendo utilizadas as mesmas classes para a categorização dos resultados do ano de 2021 (Tabela 2).

TABELA 2. Descrição das classes para classificação da taxa de crescimento vegetativo (TCV). Description of classes for classifying vegetative growth rate (VGR).

Classe	Interpretação	Intervalo de valores
1	Muito baixa	(0 – 0,0014)
2	Baixa	(0,0014 – 0,0124)
3	Média	(0,0124 – 0,0234)
4	Alta	(0,0234 – 0,0345)
5	Muito alta	(0,0345 – 0,0455)

## Análise do NDVI versus produtividade para geração de zonas de manejo (ZM)

Para uma análise preliminar referente a geração de zonas de manejo (ZM) no pomar, os dados de NDVI foram cruzados com os dados de produtividade. Devido a problemas de colheita em 2020, apenas os dados do pomar Gestão puderam ser avaliados. Para essa análise, utilizando a metodologia descrita em Gavioli et al. (2016), foram utilizados: a) algoritmos de agrupamento de dados; b) diferentes combinações de atributos de entrada compreendendo o NDVI nos diferentes estádios fenológicos da cultura; c) verificação da redução da variância da produtividade dos mapas de ZM produzidos.

## RESULTADOS E DISCUSSÃO: Variações temporais do NDVI

A Figura 1 apresenta a variação dos índices NDVI dos pomares de macieira Fitotecnia e Gestão para a safra 2020/2021 e para a safra 2021/2022.

Para ambos os pomares, foram identificados maiores valores de NDVI a partir de 46 DASD no ano de 2021 em comparação ao ano anterior, onde estão associados à maior presença de vegetação. Diversos fatores contribuem para variações temporais de NDVI em pomares de espécies frutíferas perenes, como a quantidade de horas-frio, acumulado de precipitação e variações de temperatura máxima e mínima, que podem impactar de forma positiva ou negativa o desenvolvimento vegetativo da planta para o ano seguinte (PETRI et al, 2012).

Além disso, os resultados demonstraram uma tendência temporal de crescimento dos valores de NDVI (Figura 1). Para o pomar Fitotecnia em 2020, os valores médios de NDVI variaram entre 0,115 nos 17 DASD e 0,355 em 59 DASD. Em 2021, foram encontrados entre 0,175 (16 DASD) e 0,420 (66 DASD). Essa tendência foi identificada também no pomar Gestão, em 2020 os valores variaram entre 0,115 e 0,350; para 2021, obteve-se NDVI variando entre 0,100 e 0,395. É natural que exista uma evolução da área foliar das plantas a partir da superação da dormência, fato evidenciado pelos resultados obtidos neste trabalho.




Figura 1. Valores médios do índice de vegetação (NDVI) das leituras realizadas nos pomares Fitotecnia e Gestão em 2020 e 2021. Average values of vegetation index (NDVI) from Fitotecnia and Gestão orchards in 2020 and 2021.

Nesse sentido, espera-se que menores valores de NDVI sejam identificados no período de dormência da planta, e maiores valores identificados ao longo do ciclo vegetativo até sua estabilização, com enfolhamento máximo das plantas. No caso deste experimento, a quebra de dormência foi realizada no dia 28/ago/2020 e, no ano seguinte, em 27/ago/2021, sendo perceptível a tendência de incremento do NDVI ao longo do mês de setembro e outubro, que corresponde ao período entre 16 a 40 dias após a superação da dormência (DASD) (Tabela 1). Dessa forma, a avaliação dos padrões de NDVI dos anos de 2020 e 2021 reflete o comportamento natural dos estádios de desenvolvimento fenológico da macieira, considerando o período de realização das leituras. Evolução similar de NDVI foi encontrada por Pauletto et al (2019) para pomares de maçã na mesma região, corroborando com os resultados encontrados neste trabalho.

Os valores de NDVI obtidos a partir de 59 DASD apresentaram tendência à estabilidade (Figura 1), o que pode indicar suspensão do crescimento vegetativo dos pomares. Isso pode ser explicado pelo fato de que a partir de

um dado momento a energia da planta que estava sendo utilizada para o aumento de área foliar passa a ser direcionada para o desenvolvimento dos frutos (PALLARDY, 2010). Na fenologia da macieira, os 59 DASD correspondem a fase de crescimento reprodutivo, quando os fotoassimilados produzidos pela planta são direcionados prioritariamente aos frutos em detrimento ao crescimento vegetativo (folhas, ramos, etc.) (NACHTIGALL; DECHEN, 2006). Assim, ocorre um período contínuo de evolução dos valores de NDVI seguido por um período de estabilidade ou, até mesmo, de redução. Dessa forma, os resultados das leituras de NDVI indicaram que o período de 24 até 59 DASD foi o ideal para avaliação da evolução da biomassa e, conseqüentemente, da velocidade de crescimento vegetativo nos pomares Fitotecnia e Gestão.

### Tendências da taxa de crescimento vegetativo (TCV)

A partir do cálculo da derivada do NDVI, obteve-se TCV da cultura ao longo do tempo com o objetivo de determinar a velocidade de evolução da biomassa ao longo da série temporal de estudo, assim como identificar os períodos de maior ou menor crescimento vegetativo. Caracterizou-se a TCV em diferentes classes, sendo a classe igual a 1 correspondente a uma taxa de crescimento muito baixa, e a classe igual a 5 indica taxa de crescimento muito alta (Tabela 2).

Verificou-se presença de TCV média no período de 24 a 38 DASD (meados de setembro até meados de outubro) para o pomar Fitotecnia em 2020 (Figura 2). De forma semelhante, os resultados obtidos para 2021 indicaram TCV média e alta a partir de 25 a 40 DASD (Figura 3). Isto é, o pico de velocidade de crescimento vegetativo foi identificado no período supracitado, que corresponde ao final de setembro e início de outubro.

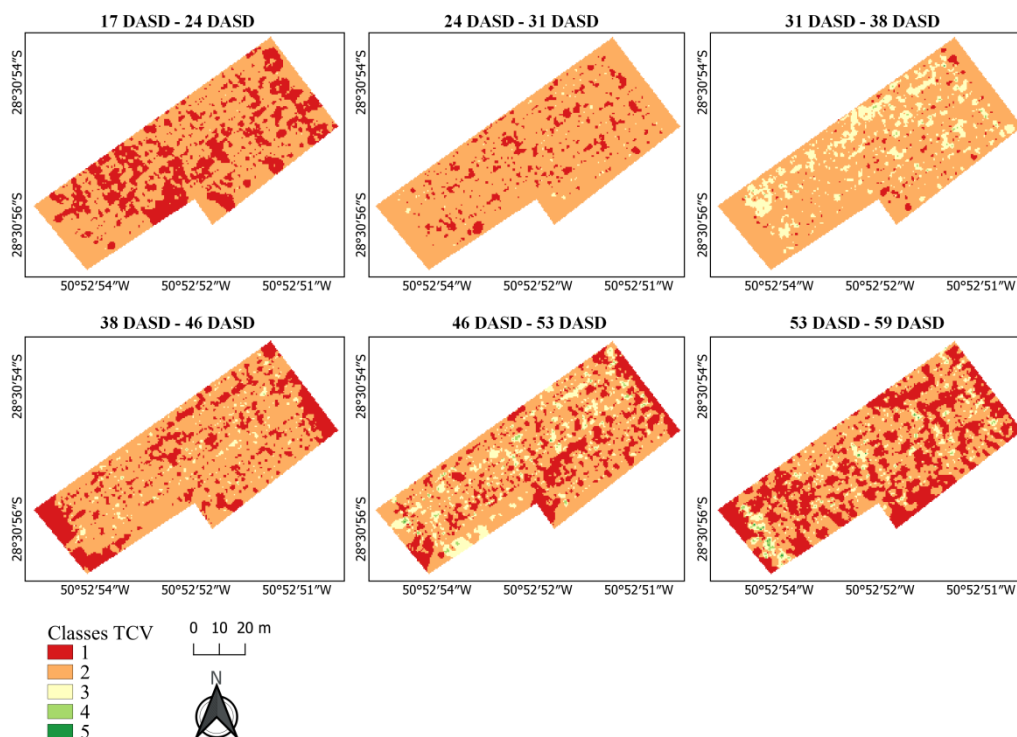


FIGURA 2. Mapas da taxa de crescimento vegetativo (TCV) no pomar Fitotecnia em 2020. Classified vegetative growth rate (VGR) maps at Fitotecnia orchard in 2020.

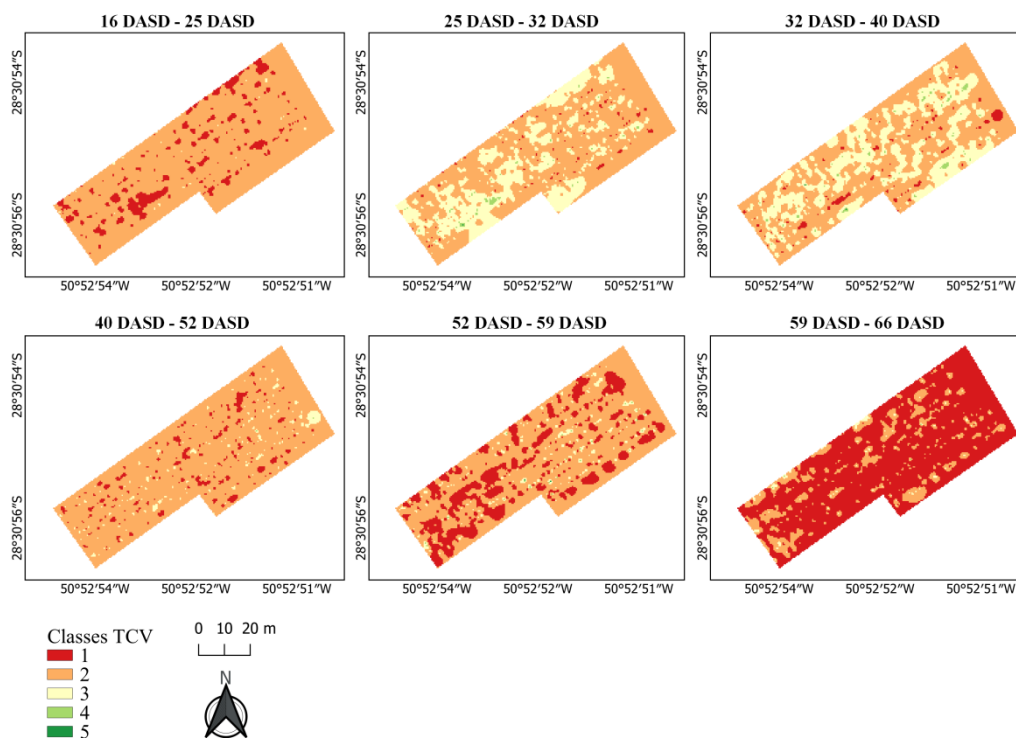


FIGURA 3. Mapas da taxa de crescimento vegetativo (TCV) no pomar Fitotecnia em 2021. Classified vegetative growth rate (VGR) maps at Fitotecnia orchard in 2021.

A TCV de uma planta ao longo do tempo pode ser relacionada como vigor. Dessa forma, pode-se inferir que entre 25 e 40 DASD representou o período de maior velocidade de desenvolvimento de biomassa, caracterizando o período ideal para captura de imagens de sensoriamento remoto com o intuito de avaliação do vigor do pomar.

A partir de 52-53 DASD, observou-se predominância de TCV baixa e muito baixa (Figuras 2 e 3), o que pode indicar que a cultura está dando sinais de estabilização de crescimento. Os resultados desta etapa estão em consonância com a tendência observada na avaliação temporal do NDVI, que apresentou aumento significativo no período de setembro a início de outubro e estabilização da taxa de crescimento ao final de outubro.

A tendência de comportamento da TCV observado no pomar Fitotecnia é semelhante entre os anos de 2020 e 2021. A partir da avaliação temporal, identificou-se um padrão de crescimento vegetativo nessa área relacionado com as estádios fenológicos da macieira, porém na média, os resultados da taxa de crescimento para o ano de 2021 são mais significativos, sendo que a maior taxa para 2020 foi de 0,014, enquanto para 2021 foi de 0,018 (Figura 4).




FIGURA 4. Taxa de crescimento vegetativo (TCV) média nos pomares Fitotecnia e Gestão ao longo do tempo. Time-series average vegetative growth rate (VGR) in Fitotecnia and Gestão orchards.

Para o pomar Gestão, os resultados da TCV são semelhantes nos anos de 2020 e 2021 (Figura 4). No entanto, em 2021, notou-se uma redução drástica na taxa de crescimento aos 52 DASD, o que não ocorreu no ano anterior. Sugere-se que isso pode ser um indicativo da variabilidade intrínseca ao desenvolvimento vegetativo da macieira na região dos Campos de Cima da Serra quando comparamos diferentes safras, mas também, principalmente, pela baixa precipitação pluviométrica nesse ano comparado ao ano anterior no período do estudo; em 2020 a precipitação acumulada de julho a novembro foi de 1.471,2 mm enquanto, em 2021, a precipitação acumulada de julho a novembro foi de 577,0 mm (Inmet, 2022). Além disso, em média, a TCV para a última semana de leitura de NDVI realizada no pomar em 2020, que corresponde a 59 dias ASD, é igual a zero (Figura 4), o que corrobora com a estabilidade do desenvolvimento de biomassa constatada na análise temporal do NDVI.

Apesar da tendência de velocidade de crescimento de biomassa para o pomar Gestão ter sido semelhante nos anos analisados, para 2020 a TCV entre 24 e 38 DASD foi, em grande parte, considerada como baixa (Figura 5), enquanto que para 2021, a TCV no mesmo período deu-se, principalmente como média (Figura 6). Após esse período, para ambos os anos de análise, observamos aumento de área correspondente à TCV baixa e muito baixa, sinalizando redução na velocidade de desenvolvimento de biomassa e, conseqüente estabilidade no crescimento vegetativo.

A totalidade de área classificada com TCV média e alta foi mais significativa em 2021 (Figura 6). O que é um indicativo de que uma maior área do pomar se desenvolveu com maior velocidade em 2021 quando comparado ao ano anterior. Resultados significativos de trabalhos que correlacionam diferentes parâmetros agrônômicos com a estimativa de vigor de pomares podem ser encontrados na literatura (VIAU, 2005; BEST, 2008; TRANBAQUINI, 2021), dentre eles o NDVI, que pode ser relacionado com a velocidade de desenvolvimento de biomassa, que por sua vez pode ser considerada como um indicador do vigor da cultura. Isso corrobora os resultados obtidos que demonstraram haver períodos de maior TCV relacionado com NDVI mais alto reforçando o uso desse índice como uma ferramenta válida e eficiente para correlacionar a formação de biomassa com o vigor do pomar.

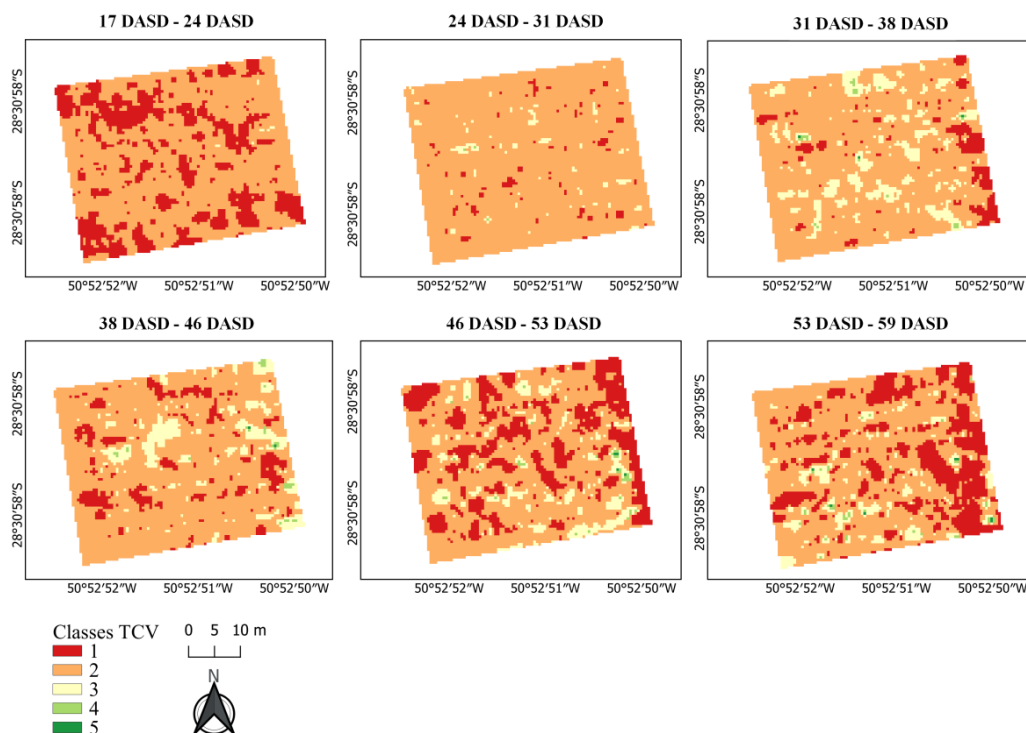


FIGURA 5. Mapas da taxa de crescimento vegetativo (TCV) no pomar Gestão em 2020. Classified vegetative growth rate (VGR) maps at Gestão orchard in 2020.

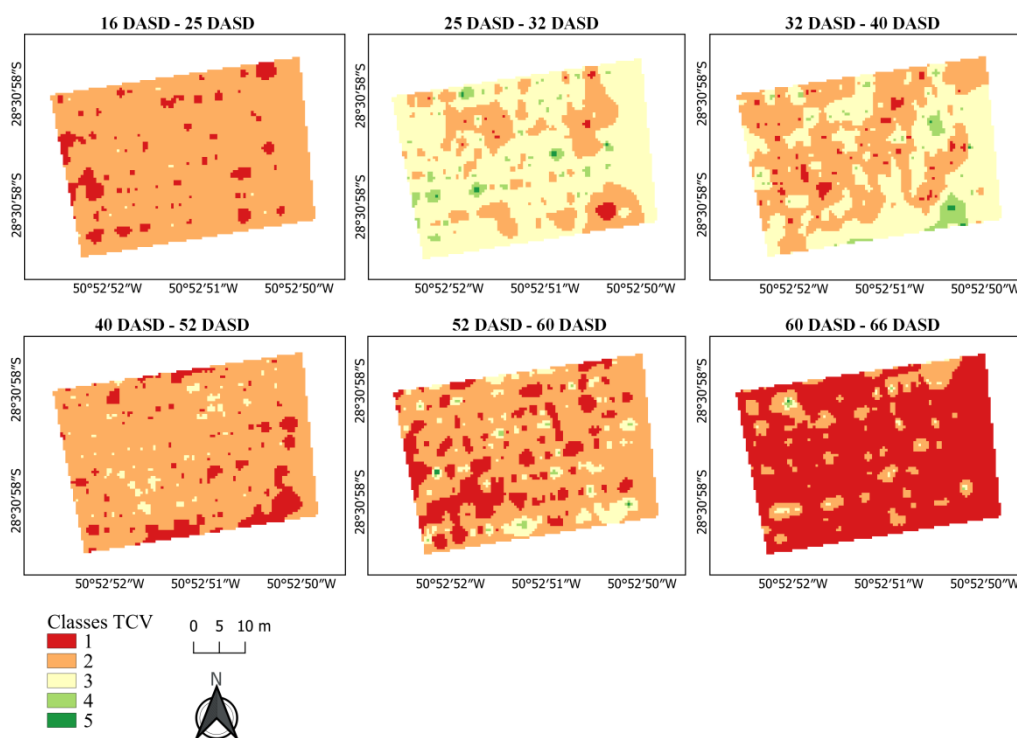


FIGURA 6. Mapas da taxa de crescimento vegetativo (TCV) para o pomar Gestão em 2021. Classified vegetative growth rate (VGR) maps at Gestão orchard in 2021.

Partindo-se do princípio de que o vigor assegura o equilíbrio entre as fases vegetativa e reprodutiva da planta, seu manejo é de grande interesse para os produtores. Nesse sentido, identificar a variabilidade espacial e temporal do vigor utilizando o NDVI pode beneficiar a gestão da cultura e tornar homogênea a qualidade e a quantidade da produção (OLDONI et al, 2021; BRAMLEY et al., 2011); o que, a partir dos resultados preliminares obtidos neste trabalho, pode vir a ser mais bem explorado para a gestão da cultura de macieiras. Os resultados desta pesquisa indicam a relação entre o NDVI e o vigor, mas também apontam ser possível identificar padrões temporais de velocidade de crescimento vegetativo ao longo do ciclo de desenvolvimento de biomassa em pomares de maçã a partir da TCV.

### Geração de zonas de manejo (ZM) com base no NDVI e na produtividade

Para avaliação da relação entre o NDVI e a produtividade, foram considerados mapas contendo de 2 a 5 ZM. Os resultados indicaram que os dados de NDVI obtidos nos estádios de Brotação (BT), Queda de pétalas (QP) e Crescimento na leitura 07 (C3), que correspondem a 24, 38 e 59 DASD respectivamente, são os mais importantes e correlacionados com a produtividade (Tabela 3). Isso sugere que esses são os períodos temporais que mais contribuem para geração de mapas de ZM com alta redução da variância da produtividade. Assim, a coleta de dados de NDVI nos demais estádios fenológicos tem pouco impacto na obtenção de ZM com o intuito de gestão da produtividade.

TABELA 3. Porcentagem de redução de variância considerando a produtividade como variável alvo, para o agrupamento gerado por dados de NDVI em cada estágio fenológico ou combinação deles. Percentage of variance reduction considering yield as the target variable, for clustering generated by NDVI data at each phenological stage or combination of them.

#ZM	Redução percentual da variância da produtividade									
	PV	BT	FL	QP	C1	C2	C3	CT	Todas	BT-QP-C3
DASD	17	24	31	38	46	53	59	-	-	-

2	0,00	24,02	7,09	26,12	-0,02	0,43	31,29	1,04	-0,02	19,84
3	9,00	25,16	22,64	26,06	21,80	3,60	32,09	19,56	12,73	27,58
4	27,01	33,42	24,29	0,00	21,79	16,97	34,53	19,76	14,91	32,29
5	8,28	18,47	11,12	0,00	5,52	13,48	20,02	15,05	30,39	9,24

ZM=Número de zonas de manejo; PV=Ponta Verde; BT=Brotação; FL=Início da Floração (leitura 03); QP=Queda de Pétalas (leitura 04); C1=Crescimento (leitura 05); C2=Crescimento (leitura 06); C3=Crescimento (leitura 07); CT=combinação de C1, C2 e C3; Todas=combinação de todos os estádios; BT-QP-C3 (combinação dos estádios de Brotação, Queda de Pétalas e Crescimento na leitura 07).

**CONCLUSÃO:** Este trabalho define um método rápido e relativamente pouco dispendioso para a identificação dos períodos de maior ou menor velocidade de crescimento vegetativo em pomares de macieira por meio da avaliação da TCV, obtida a partir do NDVI, e pode auxiliar no processo de definição de ZM considerando a produtividade como variável alvo. Os resultados indicaram que existe um padrão temporal de crescimento vegetativo nos pomares avaliados, com maior crescimento vegetativo entre 24 e 40 dias após a superação da dormência. Os padrões de velocidade de crescimento vegetativo podem ser relacionados com a caracterização temporal do vigor da cultura. A metodologia apresentada pode ser útil para a identificação dos períodos mais relevantes de aquisição de dados sobre o desenvolvimento vegetativo do pomar e, conseqüentemente, dos períodos que mais contribuem para análises com o objetivo de aumento da produtividade, como a definição de ZM, auxiliando na melhoria do desempenho das práticas de gestão do pomar e proporcionando maior eficiência nos processos de tomada de decisão.

#### REFERÊNCIAS

ASNER, G. P. Biophysical and Biochemical Sources of Variability in Canopy Reflectance. *Remote Sensing Environmental*, v. 64, p. 234-253, 1998.

BADJANA, H. M.; OLOFSSON, P.; WOODCOCK, C. E.; HELMSCHROT, J.; WALA, K.; AKPAGANA, K.. Mapping and estimating land change between 2001 and 2013 in a heterogeneous landscape in West Africa: Loss of forestlands and capacity building opportunities. **International Journal of Applied Earth Observation and Geoinformation**, v. 63, n. 63, p. 15–23, 2017.

BARROS, P. P. da S.; ROSALEN, D. L.; IOST, F. H.; MARTINS, G. D.; LEO, N. D.. Monitoramento Fitossanitário Utilizando Sensoriamento Remoto: Avanços e Desafios. **Revista Brasileira de Cartografia**, v. 73, n. 2, p. 489–515, 2021.

BEST, S.; SALAZAR, F.; LEON, L. Crop Load Estimation Model to Optimize Yield - Quality Ratio in Apple Orchards, *Malus Domestica* Borkh, Var. Royal Gala. **Journal of Information Technology in Agriculture**, v. 3, 2008.

BONILLA, I.; MARTINEZ DE TODA, F.; MARTÍNEZ-CASASNOVAS, J. A. Vine vigor, yield and grape quality assessment by airborne remote sensing over three years: Analysis of unexpected relationships in cv. Tempranillo. **Spanish Journal of Agricultural Research**, v. 13, n. 2, 2015.

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. **Australian Journal of Grape and Wine Research**, v. 17, n. 2, p. 217–229, 2011.

CANCELA, J. J.; FANDIÑO, M.; REY, B. J.; DAFONTE, J.; GONZÁLEZ, X. P. Discrimination of irrigation water management effects in pergola trellis system vineyards using a vegetation and soil index. **Agricultural Water Management**, v. 183, p. 70–77, 2017.



- GAVIOLI, A.; SOUZA, E. G.; BAZZI, C. L.; GUEDES, L. P. C.; SCHENATTO, K. Optimization of management zone delineation by using spatial principal components. **Computers and Electronics in Agriculture**, v. 127, p. 302-310, 2016.
- INMET – INSTITUTO NACIONAL DE METEOROLOGIA. Banco de dados meteorológicos. Disponível em: <https://bdmep.inmet.gov.br/> Acesso em: 14 abr. 2022
- HALL, A.; LAMB, D. W.; HOLZAPFEL, B. P., LOUIS, J. P. Within-season temporal variation in correlations between vineyard canopy and winegrape composition and yield. **Precision Agriculture**, v. 12, n. 1, p. 103–117, 2010.
- HALL, A.; LOUIS, J.; LAMB, D. Characterising and mapping vineyard canopy using high-spatial-resolution aerial multispectral images. **Computers & Geosciences**, [s. l.], v. 29, n. 7, p. 813–822, 2003.
- NACHTIGALL, G. R.; DECHEN, A. R. Seasonality of nutrients in leaves and fruits of apple trees. **Scientia Agricola**, v. 63, n. 5, p. 493–501, 2006.
- 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**, [s. l.], v. 78, n. 4, 2021. PEEL, M. C.; FINLAYSON, B. L.; MCMAHON, T. A. Updated world map of the Köppen-Geiger climate classification. **Hydrology and Earth System Sciences**, [s. l.], v. 11, n. 5, p. 1633–1644, 2007.
- PALLARDY, S. G. **Physiology of Woody Plants**. [S. l.]: Academic Press, 2010.
- PEEL, M. C.; FINLAYSON, B. L.; MCMAHON, T. A. Updated world map of the Köppen-Geiger climate classification. **Hydrology and Earth System Sciences**, v. 11, n. 5, p. 1633–1644, 2007.
- PETRI, J. L.; HAWERROTH, F. J.; LEITE, G. B.; COUTO, M.; FRANCESCATTO, P. Apple phenology in subtropical climate conditions. In: ZHANG, X. (org.). **Phenology and Climate Change**. [S. l.]: InTech, 2012. p. 195–216.
- SANTOS, M. da S.; GEBLER, L.; SEBEM, E. Correlation between vegetation indexes generated at Vitis Vinifera L. and soil, plant and production parameters for emergency application in decision making. **Ciência Rural**, [s. l.], v. 52, n. 2, 2022.
- SINHA, R.; QUIRÓS, S; SANKARAN, L; KHOT, L.. High resolution aerial photogrammetry based 3D mapping of fruit crop canopies for precision inputs management. **Information Processing in Agriculture**, 2021.
- VÉLEZ, S.; RANÇON, F.; BARAJAS, E.; BRUNEL, G.; RUBIO, J. A.; TISSEYRE, B. Potential of functional analysis applied to Sentinel-2 time-series to assess relevant agronomic parameters at the within-field level in viticulture. **Computers and Electronics in Agriculture**, v. 194, p. 106726, 2022. Disponível em: Acesso at: 13 Apr. 2022.
- VIAU, A. A.; JANG, J. D.; PAYAN, V.; DEVOST, A. The Use of Airborne LIDAR and Multispectral Sensors for Orchard Trees Inventory and Characterization. In: 7TH Information And Technology For Sustainable Fruit And Vegetable Production, 2005, Montpellier, France. **Anais [...]**, 2005.
- ZARCOTEJADA, P.; BERJÓN, A.; LÓPEZ-LOZANO, R.; MILLER, J. R.; MARTÍN, P.; CACHORRO, V.; GONZÁLEZ, 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.
- 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, **Proceedings**, NASA SP-351, NASA, Washignton, DC, v. 1, p. 309-317, 1973.

GAMON, J. A.; FIELD, C. B.; GOULDEN, M. L.; GRIFFIN, K. L.; HARTLEY, A. E.; JOEL, G.; PENUELAS, J.; VALENTINI, R. Relationships Between NDVI, Canopy Structure, and Photosynthesis in Three Californian Vegetation Types. **Ecological Applications**, v. 5, n. 1, p. 28–41, 1995.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento Remoto da Vegetação**. 2. Ed. São Paulo: Oficina de Texto, p. 176. 2012.

# Aplicação de texturas em imagens digitais coletadas por RPA para estimativa de biomassa de pastagem

Rodrigo Greggio de Freitas<sup>1</sup>; Gleyce Kelly Dantas Figueiredo<sup>3</sup>; Lucas Rios do Amaral<sup>2</sup>

<sup>1</sup>Eng. Agrônomo, Doutorando - Faculdade de Engenharia Agrícola - FEAGRI, UNICAMP. r228594@dac.unicamp.br / (17) 9 9771-8731; <sup>2</sup>Eng. Agrônomo, Prof. Dr. - Faculdade de Engenharia Agrícola - FEAGRI, UNICAMP; <sup>3</sup>Tec. Construção Civil, Prof. Dra. - Faculdade de Engenharia Agrícola - FEAGRI, UNICAMP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Analisar imagens de sensores remotos para tomada de decisão em cultivos agrícolas é uma perspectiva atual, entretanto nem sempre as informações extraídas das bandas e índices de vegetação estabelecem relações confiáveis. A derivação de texturas de níveis de cinza a partir de camadas espectrais é um recurso empregado recentemente para avaliação de parâmetros biofísicos da vegetação, como a biomassa. Mais frequentes em imagens de satélites, as texturas são menos estudadas em imagens de aeronave remotamente pilotadas (RPAs), cujas peculiaridades espectrais e de resolução espacial podem aumentar a complexidade quanto ao entendimento desta informação. Sendo assim, o objetivo deste trabalho foi explorar o uso de texturas para incrementar os resultados de modelos de predição de biomassa em pastagem cultivada utilizando imagens de RPA. Diferentes composições de modelos com bandas individuais, índices de vegetação e texturas foram avaliados com o algoritmo Random Forest. Os modelos com adição das texturas apresentaram os melhores resultados de predição em relação aos modelos apenas com bandas e índices de vegetação. Assim, concluímos que essa técnica apresenta potencial de ser utilizada em modelos de predição de propriedades biométricas das culturas e precisa ser mais explorada na agricultura de precisão.

**PALAVRAS-CHAVE:** drone; matriz níveis de cinza; sensoriamento remoto

## APPLICATION OF TEXTURES IN DIGITAL IMAGES COLLECTED BY RPA TO ESTIMATE PASTURE BIOMASS

**ABSTRACT:** Remote sensing image used in agriculture are an actual perspective; however, information from bands and vegetation indices does not always establish reliable relations. Grey-level co-occurrence textures derived from spectral layers are recently employed to assess biophysical crop parameters such as biomass. Most frequently applied to satellite images, it is less studied for remotely piloted aircraft (RPA) images which peculiarities may become information complex. Our objective was to test if GLCM textures applied to RPA images could improve cultivated pasture biomass prediction. The Random Forest algorithm assessed models with various bands, vegetation indices, and textures. Models containing textures overcame models just with bands and vegetation indices. Thus, we concluded that textures are viable techniques for biometric crop studies using prediction models, and further research is needed for precision agriculture development.

**KEYWORDS:** UAV; GLCM; remote sensing

**INTRODUÇÃO:** A crescente disponibilidade de dados de sensoriamento remoto (SR) gera alternativas para o estudo da vegetação com o objetivo de fornecer melhor suporte às atividades agrícolas (KAMILARIS *et al.*, 2017). Os índices de vegetação (IV) derivados de dados espectrais são uma das aplicações mais conhecidas neste sentido. Gerados a partir de operações matemáticas aplicadas aos dados das bandas espectrais, eles objetivam realçar respostas da vegetação, minimizando ruídos como a interferência do solo e da variação da irradiação solar (JACKSON e HUETE, 1991). Entretanto, nem sempre os resultados obtidos refletem relações lógicas com os parâmetros de avaliação desejados, haja vista a complexidade do fenômeno espectral estudado.

A melhoria destas relações é motivo de estudo e um dos caminhos pesquisados é pela utilização de dados auxiliares. Neste sentido, uma das possibilidades é a aplicação de medidas de texturas que são informações computadas a partir do dado tonal dos pixels das imagens. Elas têm aplicações em diversos campos da ciência

e no SR da vegetação podem ser calculadas a partir dos dados espectrais das bandas ou dos IVs. Haralick et al., (1973) desenvolveram texturas denominadas de matrizes de co-ocorrência em níveis de cinza (*Grey-Level Co-Occurrence Matrix* - GLCM) ao estabelecer valores singulares e normalizados para representar a frequência tonal de pares de pixels em função da sua espacialidade, ou seja, uma representação de arranjos estruturais na superfície em relação ao meio. O intuito foi o de auxiliar a classificação de imagens, mas recentemente, as texturas tem sido aplicadas na melhoria de modelos preditivos (REIS *et al.*, 2020; SARKER e NICHOL, 2011; ZHOU *et al.*, 2017), como por exemplo, para avaliação biofísica da vegetação.

Apesar de consistentes resultados na avaliação de parâmetros como biomassa e altura em imagens de satélite (REIS *et al.*, 2020; SARKER e NICHOL, 2011) sua aplicação generalizada ainda carece de maior profundidade em função da variabilidade dos cálculos representados pelos diversos tipos de texturas e suas configurações. Menos frequentes são os estudos que tratam da aplicação das texturas em imagens de aeronaves remotamente pilotadas (RPAs) que, além das variações mencionadas, adiciona um fator extra relativo às respostas espectrais, reconhecidamente singulares em relação às experimentadas imagens de satélites. Neste sentido, o objetivo desta pesquisa foi explorar o uso de texturas para incrementar os resultados de modelos de predição de biomassa em pastagem cultivada utilizando imagens de RPA.

**MATERIAIS E MÉTODOS:** O experimento foi conduzido em uma fazenda de reprodução de gado de corte no município de Caiuá/SP. A área experimental de 200ha foi cultivada com braquiária (*Urochloa ruziziensis*) e imageada com uma RPA nos meses de julho, agosto e novembro de 2019, uma vez que dados temporais múltiplos permitem abranger mais apropriadamente a variação espaço-temporal da cobertura vegetal. Isso contribui para a melhor modelagem de dados preditivos de biomassa (POLEY e MCDERMID, 2020).

Ao todo, 181 pontos amostrais georreferenciados e dispostos ao longo de toda a área experimental foram considerados para as três campanhas. As amostras físicas foram delimitadas por um gabarito de 1,0 m<sup>2</sup> e toda biomassa acima do solo foi removida, acondicionada em sacos e enviadas ao laboratório para determinação da biomassa seca (PS) após atingir peso constante (g m<sup>-2</sup>) sob temperatura de 65°C.

Antes da coleta da biomassa houve sinalização dos pontos amostrais utilizando a borda da área limitada pelo gabarito para facilitar a visualização nas imagens coletadas pela RPA. O quadricóptero modelo G-45 da GDrones realizou um plano de voo automatizado a 115,0 metros de altura carregando o sensor MicaSense RedEdge TM com bandas nas faixas do azul (B: 465–485 nm), verde (G: 550–570 nm), vermelho (R: 663–673 nm), red-edge (RE: 712–722 nm) e infravermelho próximo (NIR: 820–860 nm). Seguindo orientações da fabricante (MicaSense, Seattle, Washington, USA) foi garantida uma sobreposição frontal e lateral das imagens de 75% para uma resolução espacial de 0,08m. Coletamos imagens do painel de refletância fornecido pela fabricante, antes e após cada voo para posterior correção radiométrica. Os ortomosaicos foram elaborados com o software Agisoft Metashape® bem como a correção radiométrica.

Os ortomosaicos deram origem a camadas de dados representadas pelas bandas do sensor e pelos IVs calculados. Um conjunto de 25 IVs mais utilizados para estudo de biomassa foram calculados a partir das bandas disponíveis do sensor que, somadas a estas, totalizaram 30 camadas de dados, ou variáveis preditoras (Tabela 1). Em cada camada usamos uma máscara para extrair o valor médio do conjunto de pixels de cada ponto amostral, sinalizado previamente pelo limite do gabarito.

**TABELA 1.** Lista de índices de vegetação (IVs) utilizados para predição de biomassa com suas respectivas fórmulas e referências. **Vegetation indices (VIs) list used to predict biomass, and respective formulas and references.**

Índice de vegetação	Fórmula	Referência
1 Chlorophyll index - Clgreen	$(NIR/G) - 1$	Gitelson et al. (2003)
2 Chlorophyll index - red edge - CIRE	$(NIR/RE) - 1$	Gitelson et al. (2003)
3 Chlorophyll vegetation index - CVI	$NIR \times R / G^2$	Vincini et al. (2008)
4 Enhanced vegetation index - EVI	$2,5(NIR - R) / (NIR + 6^*R - 7,5^*B + 1)$	Huete et al. (2002)
5 Green leaf index - GLI	$(2^*G - R - B) / (2^*G + R + B)$	Louhaichi et al. (2001)
6 Green normalized difference vegetation index - GNDVI	$(NIR - G) / (NIR + G)$	Huete et al. (2002)
7 Modified chlorophyll absorption reflectance index - MCARI	$[(RE - R) - 0,2^*(RE - G)] / (RE/R)$	Adapted by Daughtry et al. (2000)
8 Combined index with MCARI - MCARI_MTVI2	MCARI/MTVI2	Eitel et al. (2007)
9 Modified chlorophyll absorption reflectance index 2 - MCARI2	$1,5^*(2,5^*(NIR-G)-1,3^*(R-G))\sqrt{(2^*NIR+1)^2-(6^*NIR-5^*\sqrt{R})-0,5)}$	Adapted by Haboudane et al. (2004)
10 Modified soil adjusted vegetation index - MSAVI	$0,5^*(2^*NIR + 1 - \sqrt{[(2^*NIR + 1)^2 - 8^*(NIR - R)]})$	Qi et al. (1994)
11 MERIS total chlorophyll index - MTCI	$(NIR - RE) / (RE - R)$	Adapted by Dash and Curran (2004)
12 Second modified triangular vegetation index - MTVI2	$1,5^*[2,5^*(NIR - G) - 2,5^*(R - G)] / \sqrt{[(2^*NIR + 1)^2 - 6^*NIR - 5^*\sqrt{R}] - 0,5}$	Haboudane et al. (2004)
13 Normalized difference red edge index - NDRE	$(NIR - RE) / (NIR + RE)$	Gitelson and Merzlyak (1994)
14 Normalized difference vegetation index - NDVI	$(NIR - R) / (NIR + R)$	Rouse et al. (1973)
15 Normalized green red difference index - NGRDI	$(G - R) / (G + R)$	Tucker (1979)
16 Normalized pigment chlorophyll ratio index - NPCI	$(R - B) / (R + B)$	Adapted by Merzlyak et al. (1999)
17 Optimized soil adjusted vegetation index - OSAVI	$(1 + 0,16)^*(NIR - R) / (NIR + R + 0,16)$	Rondeaux et al. (1996)
18 Soil adjusted vegetation index - SAVI	$(NIR - R)^*(1 + 0,5) / (NIR + R + 0,5)$	Huete (1988)
19 Ratio vegetation index (also named simple ratio) - SR	NIR/R	Jordan (1969)
20 Transformed chlorophyll absorption reflectance index - TCARI	$3^*[(RE - R) - 0,2^*(RE - G)]^*(RE/R)$	Adapted by Haboudane et al. (2002)
21 Combined index with TCARI - TCARI_OSAVI	TCARI/OSAVI	Haboudane et al. (2004)
22 Triangular greenness index - TGI	$-0,5^*[(R630 - R485)^*(R - G) - (R630 - R545)^*(R - B)]$	Hunt et al. (2011)
23 Triangular Vegetation Index - TVI	$0,5^*[120^*(NIR - G) - 200^*(R - G)]$	Broge and Leblanc (2000)
24 Visible atmospherically resistant index - VARI	$(G - R) / (G + R - B)$	Gitelson et al. (2002)
25 Visible atmospherically resistant index - red edge - VARIRE	$(RE - 1,7^*R + 0,7^*B) / (RE + 2,3^*R - 1,3^*B)$	Vina et al. (2004)

As texturas utilizadas foram as matrizes de co-ocorrência de nível de cinza (GLCM) (HARALICK et al., 1973). Escolhemos as oito texturas mais utilizadas (CLAUSI, 2002): média (A), variância (B), homogeneidade (C), contraste (D), dissimilaridade (E), entropia (F), segundo momento (G) e correlação (H). A utilização de

texturas requer a definição dos seguintes parâmetros: orientação angular entre pixels, tamanho de janela e distância de deslocamento. A variação destes ajustes pode produzir diferentes resultados e, portanto, recomenda-se testar os resultados com as diferentes variações na análise (HALL-BEYER, 2017b). Dentre as opções de variação angular estão 0°, 45°, 90°, 135° e o invariante, que é a média do resultado dos quatro ângulos e, portanto, uma medida mais generalizadora da espacialidade (HALL-BEYER, 2017b). O tamanho de janela é definido por áreas quadradas em número ímpar de pixels. A definição deste fator está diretamente relacionada com o detalhamento na imagem e resolução espacial adotada (DORIGO et al., 2012). Janelas maiores geralmente tendem a suavizar detalhes e janelas menores ficam muito dependentes do tipo de textura utilizado (PUISSANT et al., 2005). O deslocamento da janela também causa interferência na suavização dos elementos, principalmente quando distâncias maiores são utilizadas (ZHOU et al., 2017), mas poucos estudos de fato elucidaram a influência deste parâmetro.

Neste estudo utilizamos janelas com as variações de tamanho de 3x3, 5x5 e 7x7 pixels; direções angulares de 0°, 45°, 90°, 135° e invariante; e distância de um pixel para deslocamento da janela. Todos os cálculos foram realizados no software ENVI/IDL (Harris Geospatial Solutions, Inc., Broomfield, CO, USA) com uma quantização de 64 níveis de cinza. Cada uma das oito texturas e suas variações foram calculadas apenas para as bandas Verde (G), Infravermelho próximo (NIR), Red-edge (RE) e o índice de vegetação TGI, pois foram as camadas que apresentaram coeficiente de correlação de Spearman (r) maior que 0,5 para a variável PS (Figura 1). Semelhante ao procedimento adotado para as camadas espectrais, foi extraída a média dos pixels dos pontos amostrais para as camadas de textura.

Dois grupos distintos de modelos de predição foram constituídos para avaliar a quantidade de biomassa na área. O grupo 1 (G1) contendo apenas as bandas (BDs) e IVs e o grupo 2 (G2) contendo além das bandas e IVs, as texturas separadas por tamanho de janela (3x3, 5x5, 7x7) (Tabela 2). O G1 continha 30 variáveis, sendo 5 bandas e 25 IVs, e o G2, representado por três modelos com tamanhos de janelas diferentes, cada um contendo 190 variáveis correspondente às 5 bandas, 25 IVs e 160 texturas calculadas a partir de 8 texturas, 5 ângulos e 4 camadas (G, NIR, RE, TGI).

A adição de variáveis nem sempre significa melhora da modelagem, sendo recomendado a realização de testes de seleção de atributos para eliminar informação redundante ou irrelevante, resultando na redução da dimensionalidade dos dados, do custo computacional e em muitos casos melhorando o resultado e sua compreensão (CHANDRASHEKAR e SAHIN, 2014). Por esta razão, testamos resultados sem seleção de atributos e com o método Correlation Feature Selection (CFS) (PARK et al., 2005), cuja estratégia utiliza a correlação relacionada ao atributo meta (PS).

Utilizamos o algoritmo Random Forest (BREIMAN, 2001) para a predição de biomassa em função dos grupos de variáveis selecionados, o qual foi utilizado em estudos semelhantes de predição de biomassa via SR de RPA (TSOUROS et al., 2019). O coeficiente de determinação ( $R^2$ ), seguido pela análise dos erros MAE e RMSE da validação cruzada (k fold=10) norteou a comparação entre os modelos. Em cada campanha e de modo aleatório, realizamos a divisão dos dados em treino (70%) e teste (30%) para consolidar os conjuntos finais de teste e treino. As instâncias dos conjuntos de treino e teste foram sempre as mesmas para todos os modelos testados. A configuração utilizada no pacote randomForest (software R) foram:  $M(n_{tree})=150$  visando reduzir o custo computacional,  $n_{odesize}=5$ ,  $mtry=p/3$ , sendo p = número de variáveis preditoras.




FIGURA 1. Exemplo de texturas GLCM para o índice TGI, no ângulo de 90° e janela 7x7 (TGI\_90G\_7). A = média; B = variância; C = homogeneidade; D = contraste; E = dissimilaridade; F = entropia, G = segundo momento angular e H = correlação. **Example of GLCM textures of TGI with angle 90 °, and window 7x7. (TGI\_90G\_7). A = mean; B = variance; C = homogeneity; D = contrast; E = dissimilarity; F = entropy; G = angular second moment; H = correlation.**

TABELA 2. Composição de atributos dos 4 modelos testados. **Attributes composition of the 4 tested models.**

MODELOS nome	CONTEÚDO DE INFORMAÇÃO									
	camadas de dados	janela	parâmetros texturais							
<b>G1</b>	BDs + IVs	na	na	na	na	na	na	na	na	na
<b>G2_3x3</b>	BDs + IVs + Texturas (4 camadas*, 5 ângulos**)	3	A	B	C	D	E	F	G	H
<b>G2_5x5</b>	BDs + IVs + Texturas (4 camadas*, 5 ângulos**)	5	A	B	C	D	E	F	G	H
<b>G2_7x7</b>	BDs + IVs + Texturas (4 camadas*, 5 ângulos**)	7	A	B	C	D	E	F	G	H

na = não aplica; \* G, R, NIR, TGI; \*\* 0G, 45G, 90G, 135G, INVAR

**RESULTADOS E DISCUSSÃO:** Os modelos gerados com o grupo 1 de variáveis (G1 - somente com bandas e IVs) foram quase sempre superados pelos modelos G2 com adição de texturas (Tabela 3). Os resultados são mais proeminentes quando comparamos os modelos sem seleção de atributos com o método de seleção de atributos CFS.

TABELA 3. Resultados de validação dos modelos e quantidade de variáveis utilizadas para os dados sem seleção (SS) e com seleção de atributos. Os melhores modelos de cada composição de variáveis foram determinados pelo R<sup>2</sup> e erros e estão em negrito e sublinhado. **Validation results of tested models and attributes composition for No Selection and Correlation Feature Selection (CFS). Bests models of each composition are bolded, and underlined, and were determined by R<sup>2</sup> and errors.**



	SEM SELEÇÃO					CFS				
	variáveis	R <sup>2</sup>	RMSE (g m <sup>-2</sup> )	%	MAE (g m <sup>-2</sup> )	variáveis	R <sup>2</sup>	RMSE (g m <sup>-2</sup> )	%	MAE (g m <sup>-2</sup> )
G1	30	0.57	40.12	27.93	31.53	4	0.55	40.70	28.33	33.15
G2_3x3	190	0.54	40.96	28.51	32.01	9	0.61	37.37	26.01	30.12
G2_5x5	190	<u>0.58</u>	39.01	27.15	29.79	7	0.60	38.09	26.51	30.17
G2_7x7	190	0.57	39.34	27.38	30.22	6	<u>0.63</u>	36.45	25.37	28.54

O modelo G2\_7x7 com seleção de atributos alcançou o melhor resultado (R<sup>2</sup>=0,63) e menores erros (RMSE=36,45; MAE=28,54) utilizando apenas 6 variáveis preditoras. O método CFS apresentou uma destacada redução do número de variáveis utilizadas e melhoria nos resultados preditivos em relação a não utilização de seleção de atributos. O melhor modelo (G2\_7x7\_CFS) reduziu de 190 variáveis para somente 6 variáveis. Este resultado indica que a grande quantidade de informações presentes nos modelos G2, antes da seleção de atributos, apresentavam informações redundantes que acarretavam prejuízo à qualidade da predição. Além de reforçar a importância da eliminação de atributos semelhantes com consideração da predição das variáveis (PARK et al., 2005), o que é especialmente relevante quando a modelagem é baseada em poucas amostras (PADARIAN et al., 2019). Portanto, é desejável que se realize seleção de atributos para redução das variáveis com base no poder preditivo para alcançar resultados melhores e maior simplificação de modelos.

A composição de variáveis do G2\_7x7\_CFS mostra a utilização dos três tipos de dados ao selecionar 1 banda, 3 texturas e 2 IVs (Figura 2). Das 6 variáveis selecionadas, a banda NIR e a textura TGI\_C\_INVAR (IV TGI, textura homogeneidade, ângulo invariante) foram as mais relevantes, apresentando importância acima de 80% e as demais, exceto a NIR\_G\_90\_7 (banda NIR, textura segundo momento angular, ângulo 90°) que foi nula, tiveram importância alta, acima de 60%. As texturas efetivamente utilizadas neste modelo foram Homogeneidade (C) e Dissimilaridade (E).



FIGURA 2. Ranqueamento da importância dos atributos do modelo G2\_7x7\_CFS. **Attributes ranking of model G2\_7x7\_CFS.**

A interpretação da composição dos melhores modelos é complexa, mas podemos destacar a importância da diversidade de informação propiciada pela combinação de bandas, IVs e texturas, principalmente sob luz de um estudo multitemporal, quando o desenvolvimento das plantas acarreta mudanças nas respostas espectrais dificultando a análise via bandas ou índices individuais que se sujeitam a saturação ou insensibilidade às mudanças da vegetação ao longo do tempo (POLEY e MCDERMID, 2020). Destacamos também a importância da banda NIR como variável individual e na composição dos IVs e suas texturas derivadas. O NIR tem marcante presença em estudos de biomassa, principalmente na composição de IVs (POLEY e MCDERMID, 2020), pois tem a capacidade de registrar a variabilidade do desenvolvimento da vegetação no tempo, enquanto as regiões do visível podem apresentar saturação em iguais condições (ZHENG et al., 2018).

Essa complexidade relativa ao desenvolvimento da vegetação ao longo do tempo é passível de melhor registro por IVs de maior complexidade de composição, permitindo a captura da resposta espectral em diferentes faixas. A presença dos IVs MTVI2 e TGI no melhor modelo (G2 7x7 CFS), caracterizados pela composição de três bandas ou mais, corrobora neste sentido, uma vez que vegetações novas e herbáceas são mais bem caracterizadas pelo RE e seus IVs derivados do que por bandas RGB que saturam rapidamente (JIANG et al., 2019), enquanto para vegetação com estrutura mais desenvolvida, recomenda-se o uso do NIR e seus derivados, principalmente para estudo de biomassa (POLEY e MCDERMID, 2020). Logo, recomenda-se o uso da maior quantidade possível de dados espectrais para estudo de período contínuo e sob condições de campo, com especial destaque para o NIR e RE.

As texturas apresentaram resultados positivos para a predição dos modelos, mas estabelecer quais texturas são mais importantes é complexo. Uma abordagem mais compreensível é fornecida por Hall-Beyer (2017a) ao sugerir que as texturas Média, Correlação, Homogeneidade e Segundo Momento Angular estão relacionados com a identificação de padrões internos das imagens, ou seja, relacionados com a organização do padrão



espacial dos diferentes pixels, enquanto Contraste, Dissimilaridade, Entropia e Variância relacionam-se mais com a identificação de bordas que indicam mudanças bruscas dos padrões dos pixels. O melhor modelo abordou as duas situações com as texturas Homogeneidade e Dissimilaridade (padrão interno e borda, respectivamente), enquanto outros modelos tiveram maior frequência para texturas de padrões internos. Dessa forma, parece adequado a utilização de ao menos uma textura GLCM de cada situação (interno ou borda) para registrar as variações espaço-temporais, pois com o desenvolvimento da vegetação ocorrem mudanças horizontais e verticais na estrutura do dossel.

As maiores janelas (5x5, 7x7) foram em geral melhores do que as janelas 3x3 ( $R^2$  e erros - Tabela 3), indicando que para imagens com altíssima resolução espacial (0,08m), as mudanças de padrões se tornam menos visíveis em janelas menores. Nesta situação há dificuldade de ocorrência do chamado “efeito de borda”, indicativo de mudanças de padrão dentro da imagem (GIROLAMO-NETO *et al.*, 2019). A presença do efeito de borda promove melhoria na classificação de imagens e dos modelos. Deve-se considerar a resolução espacial das imagens para determinar o tamanho de janela, e também a distribuição espacial do cultivo, pois cultivos em linha produzem efeito de borda com janelas menores (ZHENG *et al.*, 2018), ao passo que dosséis homogêneos como o de florestas ou pastagens, as janelas maiores podem ser mais benéficas.

Apesar da medida angular invariante ter sido o segundo atributo mais importante no melhor modelo (G2 7x7 CFS), as texturas de ângulos específicos foram maioria nos atributos do modelo tornando difícil uma análise deste parâmetro. Desta forma, realizamos uma simulação trocando o ângulo específico das variáveis do melhor modelo (G2\_7x7\_CFS) pela medida invariante, visando maior generalização do modelo. O resultado apresentou uma pequena redução de desempenho (modelo original:  $R^2 = 0,63$ ; RMSE = 36,45; MAE = 28,54; modelo INVAR:  $R^2 = 0,61$ ; RMSE = 37,30; MAE = 28,53), mostrando-se adequada sua adoção tendo em vista a generalização e simplificação do modelo.

**CONCLUSÃO:** Nesta pesquisa testamos se o uso de texturas em imagens coletadas por RPA melhoram a predição de biomassa de pastagem cultivada.

A utilização conjunta de texturas que contemplem entendimento sobre bordas e padrões internos da imagem e de bandas do infravermelho, como o NIR, além de índices de vegetação com mais de duas bandas são importantes para o resultado de predição de biomassa de pastagem. Texturas calculadas com janelas maiores são mais indicadas para imagens de alta resolução espacial. A medida angular invariante é adequada para generalização das medidas texturais e simplificação dos modelos.

A combinação de dados texturais junto aos espectrais resultaram nas melhores estimativas, mostrando-se como um método viável para utilização de dados espectrais de alta resolução obtidos via RPA. Mais estudos dessa técnica em imagens de RPA são necessários para validação das melhores configurações de texturas em outros cenários agrícolas

## REFERÊNCIAS

BREIMAN, L. Random forests. **Machine learning**, p. 5–32, 2001. Disponível em <<http://link.springer.com/article/10.1023/A:1010933404324>>.

BROGE, N. H.; LEBLANC, E. Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. **Remote Sensing of Environment**, v. 76, n. 2, p. 156–172, 2000.

CHANDRASHEKAR, G.; SAHIN, F. A survey on feature selection methods. **Computers and Electrical Engineering**, v. 40, n. 1, p. 16–28, 2014. Disponível em <<http://dx.doi.org/10.1016/j.compeleceng.2013.11.024>>.

CLAUSI, D. A. An analysis of co-occurrence texture statistics as a function of grey level quantization. **Canadian Journal of Remote Sensing**, v. 28, n. 1, p. 45–62, 2002.

- DASH, J.; CURRAN, P. J. The MERIS terrestrial chlorophyll index. **International Journal of Remote Sensing**, v. 25, n. 23, p. 5403–5413, 2004.
- DAUGHTRY, C. *et al.* Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance. **Remote Sensing of Environment**, v. 74, p. 229–239, 2000.
- DORIGO, W. *et al.* Mapping invasive *Fallopia japonica* by combined spectral, spatial, and temporal analysis of digital orthophotos. **International Journal of Applied Earth Observation and Geoinformation**, v. 19, n. 1, p. 185–195, 2012.
- EITEL, J. U. H. *et al.* Using in-situ measurements to evaluate the new RapidEye™ satellite series for prediction of wheat nitrogen status. **International Journal of Remote Sensing**, v. 28, n. 18, p. 4183–4190, 2007.
- GIROLAMO-NETO, C. Di *et al.* Assessment of Texture Features for Bermudagrass (*Cynodon dactylon*) Detection in Sugarcane Plantations. **Drones**, v. 3, n. 2, p. 36, 2019.
- GITELSON, A. A. *et al.* Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, v. 80, n. 1, p. 76–87, 2002.
- GITELSON, A. A.; GRITZ, Y.; MERZLYAK, M. N. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. **Journal of Plant Physiology**, v. 160, n. 3, p. 271–282, 2003.
- GITELSON, A. A.; MERZLYAK, M. N. Quantitative estimation of chlorophyll-a using reflectance spectra: Experiments with autumn chestnut and maple leaves. **Journal of Photochemistry and Photobiology, B: Biology**, v. 22, n. 3, p. 247–252, 1994.
- HABOUDANE, D. *et al.* Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. **Remote Sensing of Environment**, v. 81, n. 2–3, p. 416–426, 2002.
- HABOUDANE, D. *et al.* Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. **Remote Sensing of Environment**, v. 90, n. 3, p. 337–352, 15 abr. 2004.
- HALL-BEYER, M. Practical guidelines for choosing GLCM textures to use in landscape classification tasks over a range of moderate spatial scales. **International Journal of Remote Sensing**, v. 38, n. 5, p. 1312–1338, 2017a. Disponível em <<http://dx.doi.org/10.1080/01431161.2016.1278314>>.
- HALL-BEYER, M. **GLCM Texture: a Tutorial**. Disponível em: <<https://prism.ucalgary.ca/handle/1880/51900>>. 2017b. Acesso em: 02/03/2020.
- HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural Features for Image Classification. **IEEE Transactions on Systems, Man, and Cybernetics**, v. SMC-3, n. 6, p. 610–621, 1973.
- HUETE, A. R. A Soil-Adjusted Vegetation Index (SAVI). **Remote Sensing of Environment**, v. 25, p. 295–309, 1988.
- HUETE, A. *et al.* Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, p. 195–213, 2002. Disponível em: <[www.elsevier.com/locate/rse](http://www.elsevier.com/locate/rse)>.
- HUNT, E. R. *et al.* Remote sensing leaf chlorophyll content using a visible band index. **Agronomy Journal**, v. 103, n. 4, p. 1090–1099, 2011.
- JACKSON, R. D.; HUETE, A. R. Interpreting Vegetation Indices. **Preventive Veterinary Medicine**, v. 11, p. 185–200, 1991.

- JIANG, Q. *et al.* UAV-Based Biomass Estimation for Rice-Combining Spectral, TIN-Based Structural and Meteorological Features. **Remote Sensing**, v. 11, n. 7, p. 890, 2019.
- KAMILARIS, A.; KARTAKOULLIS, A.; PRENAFETA-BOLDÚ, F. X. A review on the practice of big data analysis in agriculture. **Computers and Electronics in Agriculture**, v. 143, n. September, p. 23–37, 2017. Disponível em <<https://doi.org/10.1016/j.compag.2017.09.037>>.
- JORDAN, C. F. Derivation of Leaf-Area Index from Quality of Light on the Forest Floor. **Ecology**, v. 50, n. 4, p. 663–666, 1969. Disponível em: <<https://doi.org/10.2307/1936256>>.
- 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.
- MERZLYAK, M. N. *et al.* Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. **Physiologia Plantarum**, v. 106, n. 1, p. 135–141, 1999.
- PADARIAN, J.; MINASNY, B.; MCBRATNEY, A. B. Machine learning and soil sciences: A review aided by machine learning tools. **Soil**, v. 6, n. 1, p. 35–52, 2020.
- PARK, J. S.; SHAZZAD, K. M.; KIM, D. S. Toward modeling lightweight intrusion detection system through correlation-based hybrid feature selection. In: Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), **Anais...**2005.
- POLEY, L. G.; MCDERMID, G. J. A Systematic Review of the Factors Influencing the Estimation of Vegetation Aboveground Biomass Using Unmanned Aerial Systems. **Remote Sensing**, v. 12, n. 7, p. 1052, 2020.
- QI, J. *et al.* A modified soil adjusted vegetation index. **Remote Sensing of Environment**, v. 48, n. 2, p. 119–126, 1994.
- PUISSANT, A.; HIRSCH, J.; WEBER, C. The utility of texture analysis to improve per-pixel classification for high to very high spatial resolution imagery. **International Journal of Remote Sensing**, v. 26, n. 4, p. 733–745, 2005.
- REIS, A. A. *et al.* Monitoring Pasture Aboveground Biomass and Canopy Height in an Integrated Crop–Livestock System Using Textural Information from PlanetScope Imagery. **Remote Sensing**, v. 12, n. 16, p. 2534, 2020.
- ROBNIK-SIKONJA, M.; KONONENKO, I. Theoretical and Empirical Analysis of ReliefF and RReliefF. **Machine Learning**, v. 53, p. 23–69, 2003. Disponível em <<http://lkm.fri.uni-lj.si/xaigor/slo/clanki/MLJ2003-FinalPaper.pdf>>.
- RONDEAUX, G.; STEVEN, M.; BARET, F. Optimization of soil-adjusted vegetation indices. **Remote Sensing of Environment**, v. 55, n. 2, p. 95–107, 1996.
- ROUSE, J. W. *et al.* Monitoring vegetation systems in the great plains with ERTS. In: Third Earth Resources Technology Satellite (ERTS) symposium, **Anais...**1973. Disponível em: <<https://ntrs.nasa.gov/archive/nasa/casi.ntrs.nasa.gov/19740022614.pdf>>.
- SARKER, L. R.; NICHOL, J. E. Improved forest biomass estimates using ALOS AVNIR-2 texture indices. **Remote Sensing of Environment**, v. 115, n. 4, p. 968–977, 2011. Disponível em <<http://dx.doi.org/10.1016/j.rse.2010.11.010>>.
- TSOUROS, D. C.; BIBI, S.; SARIGIANNIDIS, P. G. A review on UAV-based applications for precision agriculture. **Information (Switzerland)**, v. 10, n. 11, 2019.
- TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, p. 127–150, 1979.

VIÑA, A. *et al.* Monitoring maize (*Zea mays* L.) phenology with remote sensing. **Agronomy Journal**, v. 96, n. 4, p. 1139–1147, 2004.

VINCINI, M.; FRAZZI, E.; D’ALESSIO, P. A broad-band leaf chlorophyll vegetation index at the canopy scale. **Precision Agriculture**, v. 9, n. 5, p. 303–319, 2008.

ZHENG, H. *et al.* Improved estimation of rice aboveground biomass combining textural and spectral analysis of UAV imagery. **Precision Agriculture**, p. 611–629, 2018.

ZHOU, J. *et al.* The Effects of GLCM parameters on LAI estimation using texture values from Quickbird Satellite Imagery. **Scientific Reports**, v. 7, n. 1, p. 1–12, 2017. Disponível em <  
<http://dx.doi.org/10.1038/s41598-017-07951-w> >.

# PREDIÇÃO DE ATRIBUTOS DE FERTILIDADE DO SOLO USANDO SENSOR XRF: COMPARAÇÃO DE MODELOS LINEARES SIMPLES, MÚLTIPLOS E PLSR

Rachel Ferraz de Camargo<sup>1</sup>; Gabriel Villela Bedum<sup>3</sup>; Tiago Rodrigues Tavares<sup>2</sup>; Murilo Oliveira Cardoso<sup>3</sup>; Hudson Wallace Pereira de Carvalho<sup>4</sup>

<sup>1</sup>Eng. de Alimentos, Mestranda - Lab. de Instrumentação Nuclear , CENA, USP, Piracicaba - SP. rachel.camargo@usp.br / (19) 9 9466-9892; <sup>2</sup>Eng. Agrônomo, Pesquisador Pós-Doc - Lab. de Instrumentação Nuclear , CENA, USP, Piracicaba - SP; <sup>3</sup>Graduando em Agronomia, Graduando - ESALQ/USP, Piracicaba - SP; <sup>4</sup>Químico, Professor - Lab. de Instrumentação Nuclear , CENA, USP, Piracicaba - SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Pensando em avançar com as aplicações do sensor de fluorescência de raios X (XRF) para avaliação da fertilidade do solo no âmbito da agricultura de precisão, esse trabalho utiliza uma metodologia transparente para aquisição de dados e, usando os espectros do XRF como variáveis independentes, avalia o desempenho de diferentes estratégias de modelagem preditiva lineares para o diagnóstico de argila, nutrientes extraíveis (ex-Ca e ex-K) e capacidade de troca de cátions (CTC) em solos tropicais. Para isso, foram utilizadas 214 amostras de solo, provenientes de cinco áreas agrícolas diferentes. Comparou-se modelos preditivos usando regressão linear simples (RLS) e regressão linear múltipla (RLM), ambos usando a intensidade de linhas de emissão específicas, e regressão por mínimos quadrados parciais, usando o espectro inteiro após passar por pré-processamentos específicos. Os modelos multivariados se mostraram claramente superiores aos modelos utilizando RLS. O PLS apresentou desempenhos superiores para a predição de argila (RPD de 3,9 para a RLM e de 4,1 para o PLS) e CTC (RPD de 2,5 para a RLM e de 2,7 para o PLS), enquanto que para a predição de ex-Ca, ambas as técnicas multivariadas apresentaram qualidade preditiva comparáveis (RPD de 2,3 para a RLM e de 2,2 para o PLS). Os resultados do presente trabalho permitem sugerir o PLS como técnica de modelagem ótima para calibração de modelos preditivos de atributos de fertilidade do solo usando dados espectrais do sensor XRF.

**PALAVRAS-CHAVE:** Modelagem preditiva; Quimiometria; Sensores Inteligentes

## SOIL FERTILITY DIAGNOSTICS VIA XRF: COMPARISON BETWEEN SIMPLE, MULTIPLE AND PARTIAL LEAST SQUARE REGRESSION MODELS

**ABSTRACT:** Thinking about the advance of X-ray fluorescence (XRF) sensor applied for soil fertility assessment within precision agriculture, this work uses a transparent methodology for data acquisition and, with the XRF spectra as independent variables, evaluates the performance of different predictive linear modeling strategies for the diagnosis of clay, extractable nutrients (ex-Ca and ex-K) and cation exchange capacity (CTC) in tropical soils. For this purpose, 214 soil samples from five different agricultural areas were used. Predictive models were compared using simple linear regression (RLS) and multiple linear regression (RLM), both using the intensity of specific emission lines, and partial least squares regression (PLS), using the entire spectrum, after going through specific preprocessing. The multivariate models proved clearly superior to the models using RLS. PLS showed superior performances for the prediction of clay (RPD of 3.9 for RLM and 4.1 for PLS) and CTC (RPD of 2.5 for RLM and 2.7 for PLS), while for the prediction of ex-Ca, both multivariate techniques showed comparable predictive quality (RPD of 2.3 for RLM and 2.2 for PLS). The results of the present work suggest PLS as an optimal modeling technique for the calibration of predictive models of soil fertility attributes, using XRF sensor spectral data.

**KEYWORDS:** Predictive Modeling; Chemometrics; Smart Sensors

**INTRODUÇÃO:** Abordagens utilizando sensoriamento próximo do solo são uma alternativa para diagnóstico da fertilidade de solos agrícolas de maneira prática e que permite intensificar a densidade espacial de informações sobre o solo de talhões agrícolas (MOLIN; TAVARES, 2019). Isso tem relevância em solos

tropicais brasileiros dada a sua acidez e baixa fertilidade natural, o que torna o país um grande importador de fertilizantes. Dentre as técnicas de sensoriamento próximo do solo, sensores de fluorescência de raios X (XRF) têm se destacado nos últimos anos (SILVA et al., 2021). Esta técnica permite a quantificação dos teores totais de vários elementos presentes no solo, tais como Si, Fe, Al, K, P e Ca. Além disso, é compatível com a análise direta de sólidos, podendo-se obter desempenhos analíticos acurados, com o mínimo ou nenhum preparo de amostra e de forma rápida (e.g. 30 segundos) (GREDILLA et al., 2016; MOLIN; TAVARES, 2019). Pesquisas recentes executadas em solos tropicais brasileiros têm apontado o potencial do sensor de XRF para diagnóstico de atributos físicos e químicos de fertilidade do solo, tal como textura, capacidade de troca de cátions (CTC), matéria orgânica (MO), macronutrientes (ex-P, ex-K, ex-Ca e ex-Mg), entre outros (SILVA et al., 2017; TEIXEIRA et al., 2018; LIMA et al., 2019; ANDRADE et al., 2020; TAVARES et al., 2020). Apesar dessas pesquisas mostrarem o potencial da técnica, a maioria dos trabalhos tem utilizado pacotes de aquisição de dados pré-programados (e.g., Soil Mode, Innov-X Systems, Waltham, MA, USA) que são fechados para otimização das condições instrumentais do equipamento. Além disso, é comum na literatura o uso das concentrações dos elementos na forma de óxidos, as quais é fornecida pelo pacote de calibração do fabricante, como variáveis explicativas para os modelos preditivos (SILVA et al., 2017; TEIXEIRA et al., 2018; LIMA et al., 2019; ANDRADE et al., 2020). Apesar dessa estratégia ser funcional para avaliação do potencial do sensor, algumas aplicações chave dentro da agricultura de precisão são inviabilizadas ao se utilizar pacotes de aquisição de dados pré-programados, i.e., construção de bibliotecas espectrais e aplicações rápidas diretamente no campo (e.g., com tempo de análise < 10 s). Isso, pois essas aplicações demandam configurações das condições instrumentais do equipamento (e.g., tempo de escaneamento) e modelagens usando diretamente os espectros XRF, no caso do desenvolvimento de bibliotecas espectrais. Neste sentido, o presente trabalho busca avaliar diferentes estratégias de modelagem que exploram diretamente os espectros XRF. Mais especificamente, comparou-se modelos preditivos para atributos de fertilidade do solo usando regressões lineares simples e regressões lineares múltiplas, ambas usando a intensidade de linhas de emissão específicas do espectro XRF, e regressão por mínimos quadrados parciais (PLSR), usando o espectro XRF inteiro. Desta forma, busca-se avançar com o conhecimento de uma estratégia de modelagem preditiva ótima para o diagnóstico da fertilidade de solos tropicais e que se baseie em uma metodologia transparente e reaplicável das configurações das condições instrumentais do sensor XRF.

**MATERIAIS E MÉTODOS:** Foram utilizadas 214 amostras de solo obtidas em cinco municípios do estado de São Paulo (Monte Azul, Patrocínio Paulista, Coronel Macedo, Catanduva e Torrinha). As mesmas foram coletadas em profundidades distintas (0 a 20; 20 a 40; e 80 a 100 cm), secas ao ar, peneiradas ( $\leq 2$  mm) e armazenadas. Posteriormente, foram enviadas para um laboratório comercial, onde foram submetidas às análises de rotina de fertilidade do solo. Os teores de argila, ex-K, ex-Ca e CTC foram determinados com a metodologia descrita por Van Raij et al. (1968). Os espectros das amostras foram adquiridos com um espectrômetro XRF portátil (modelo Tracer III-SD, Bruker AXS, Madison, WI, EUA). As medidas foram realizadas com o tubo de raios X configurado na tensão de 35 kV (corrente de 7 uA), sob pressão atmosférica e sem filtro primário, conforme indicação de Tavares et al. (2020). As cubetas foram preparadas com filme de polipropileno de 4  $\mu$ m de espessura (SPEX, Metuchen, NJ, EUA) e preenchidas com 10 g de amostra. As leituras foram efetuadas em duplicata. As intensidades das linhas de emissão e de espalhamento (Al-K $\alpha$ , Si-K $\alpha$ , P-K $\alpha$ , S-K $\alpha$ , K-K $\alpha$ , Ca-K $\alpha$ , Ti-K $\alpha$ , Cr-K $\alpha$ , Mn-K $\alpha$ , Fe-K $\alpha$ , Ni-K $\alpha$ , Cu-K $\alpha$ , Zn-K $\alpha$ , Zr-K $\alpha$ , Thomson-K $\alpha$ , Compton-K $\alpha$  e Thomson-L $\alpha$ ) foram obtidas em contagens por segundo (cps). As amostras foram divididas com o algoritmo Kennard-Stone (KENNARD & STONE, 1969) em dois conjuntos, um contendo 70% (n = 150) e outro contendo 30% (n = 64) das amostras. O conjunto maior foi utilizado na calibração e o menor na validação dos modelos preditivos. Todos os modelos foram gerados com o programa Unscrambler (Camo AS, Oslo, Noruega). Os modelos de regressão linear simples (RLS) foram calibrados utilizando a linha de emissão Ti-K $\alpha$ , para o modelo de argila, a linha K-K $\alpha$ , para o modelo de ex-K, e a linha Ca-K $\alpha$ , para o modelo de ex-Ca e CTC. Essas linhas de emissão foram escolhidas, pois corriqueiramente têm sido apresentadas como variáveis mais importantes para esses modelos em trabalhos realizados em solos tropicais (LIMA et al., 2019; ANDRADE et al., 2020; TAVARES et al., 2020). A intensidade das linhas de emissão e de espalhamento reportadas acima foram utilizadas como variáveis explicativas nos modelos de regressão linear múltipla (RLM). Já nos modelos de regressão por mínimos quadrados parciais (PLS) todos canais entre 1 e 25 keV foram utilizados como variáveis explicativas (total de 1208 variáveis explicativas). O número de variáveis latentes (VL) dos modelos PLS foi definido com base nos valores de raiz do erro quadrático médio obtido na de validação externa (RMSEP). Antes da calibração com PLS os espectros foram alinhados, utilizando o método COW (do inglês, *Correlation Optimized Warping*), para corrigir o desalinhamento de energia dos

canais. O método COW foi realizado com o *step* de 20, *slack* de 2 e utilizando como amostra de referência aquela mais próxima ao centro nos escores da análise dos componentes principais. Utilizando o RMSEP, testou-se modelos de PLS calibrados com os espectros alinhados e com três pré-processamentos espectrais (centragem na média, centragem na média + escalonamento pelo desvio padrão, e centragem na média + escalonamento pelo intervalo interquartil) (SANTOS, et al., 2021), comparando apenas o de melhor desempenho com as outras estratégias de modelagem (i.e., RLS e RLM). A Figura 1 exibe o espectro de XRF de uma amostra de solo antes e depois de aplicar os pré-processamentos.

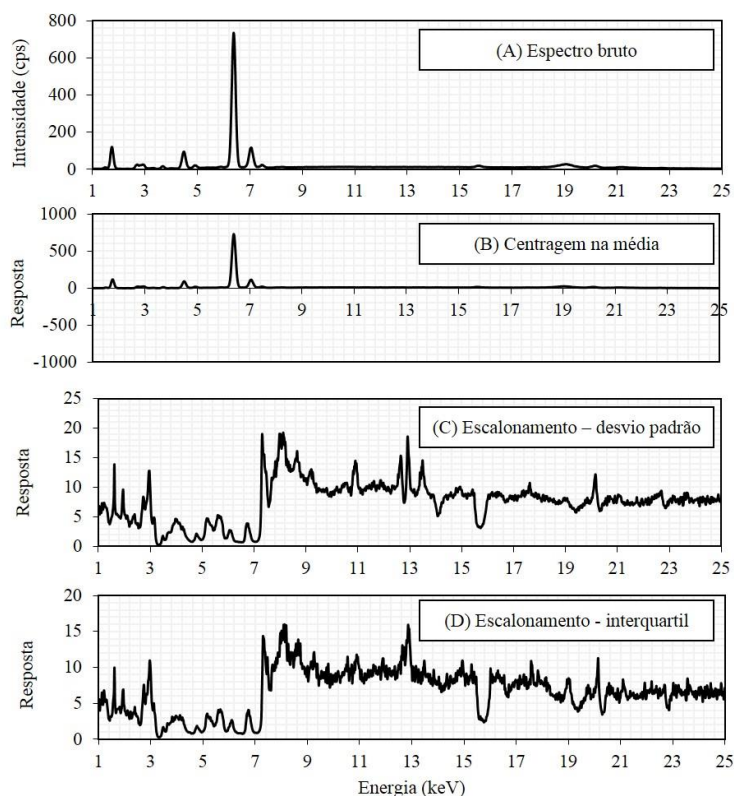


FIGURA 1. Espectro de XRF: (A) espectro bruto, (B) centragem na média, (C) Escalonamento pelo desvio padrão e (D) Escalonamento pelo intervalo interquartil. **XRF spectrum: (A) Raw spectrum, (B) mean centering, (C) Scaling by standard deviation, (D) Scaling by interquartile range.**

A qualidade dos modelos foi comparada tomando como base o coeficiente de determinação ( $R^2$ ), a raiz do erro quadrático médio (RMSE), erro relativo (RE) e o desvio percentual relativo (RPD) (CHANG et al., 2001) obtidos nos conjuntos de calibração e validação. O RE expressa o RMSE em porcentagem tomando os dados de referência como comparação. A razão de porcentagem de desvio (RPD) é bastante utilizada para avaliar a performance de modelos preditivos (CHANG et al., 2001). Ela corresponde à razão entre o desvio padrão dos dados de referência e o RMSE. O modelo pode ser considerado excelente, bom, razoável ou ruim de acordo com o RPD (Tabela 1).

TABELA 1. Classes de RPD utilizada para a avaliação da performance de modelos preditivos (CHANG et al., 2001). **RPD classes used for the performance evaluation of the predictive models (CHANG et al., 2001).**

Performance:	Excelente	Bom	Razoável	Ruim
	$RPD \geq 3,0$	$3,0 > RPD \geq 2$	$2,0 > RPD \geq 1,4$	$RPD < 1,4$

A Figura 2 mostra um fluxograma com as etapas seguidas para a execução da metodologia deste trabalho.

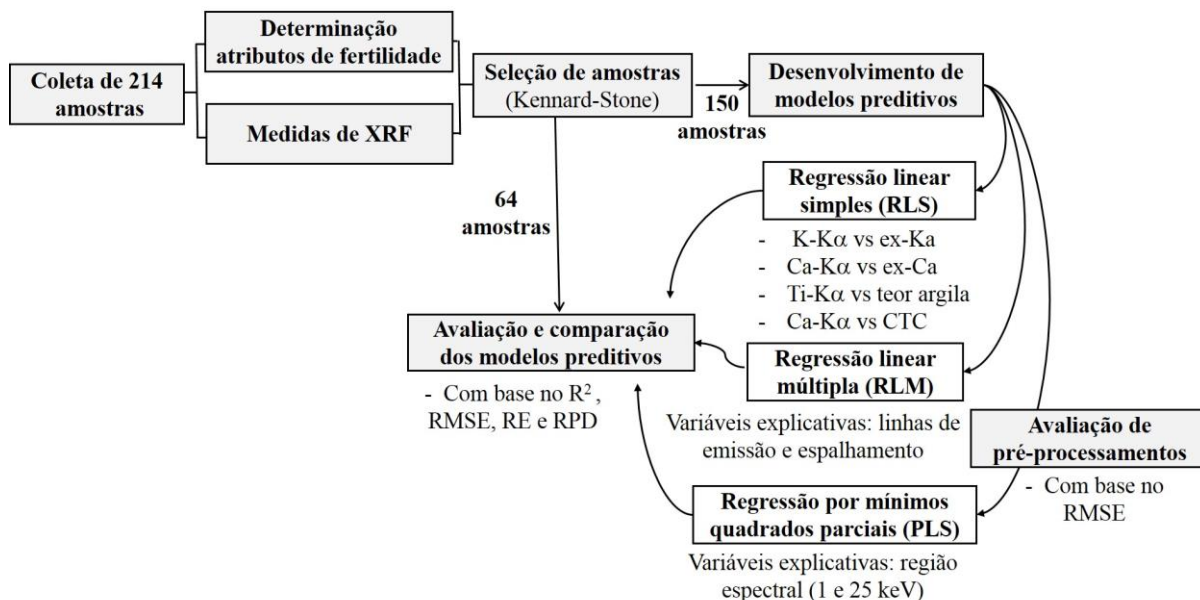


FIGURA 2. Fluxograma resumindo a metodologia adotada no presente trabalho. **Flowchart summarizing the methodology adopted in the present study.**

**RESULTADOS E DISCUSSÃO:** Os conjuntos de calibração e validação foram selecionados com o método Kennard-Stone, assegurando uma distribuição equiparável da estatística descritiva dos conjuntos de calibração e validação, o que pode ser observado na Figura 3. Isso é realizado com o intuito de evitar influências negativas no desempenho dos modelos que estejam relacionados à variação da amplitude dos valores dos conjuntos e não ao desempenho dos sensores XRF (STENBERG et al., 2010).

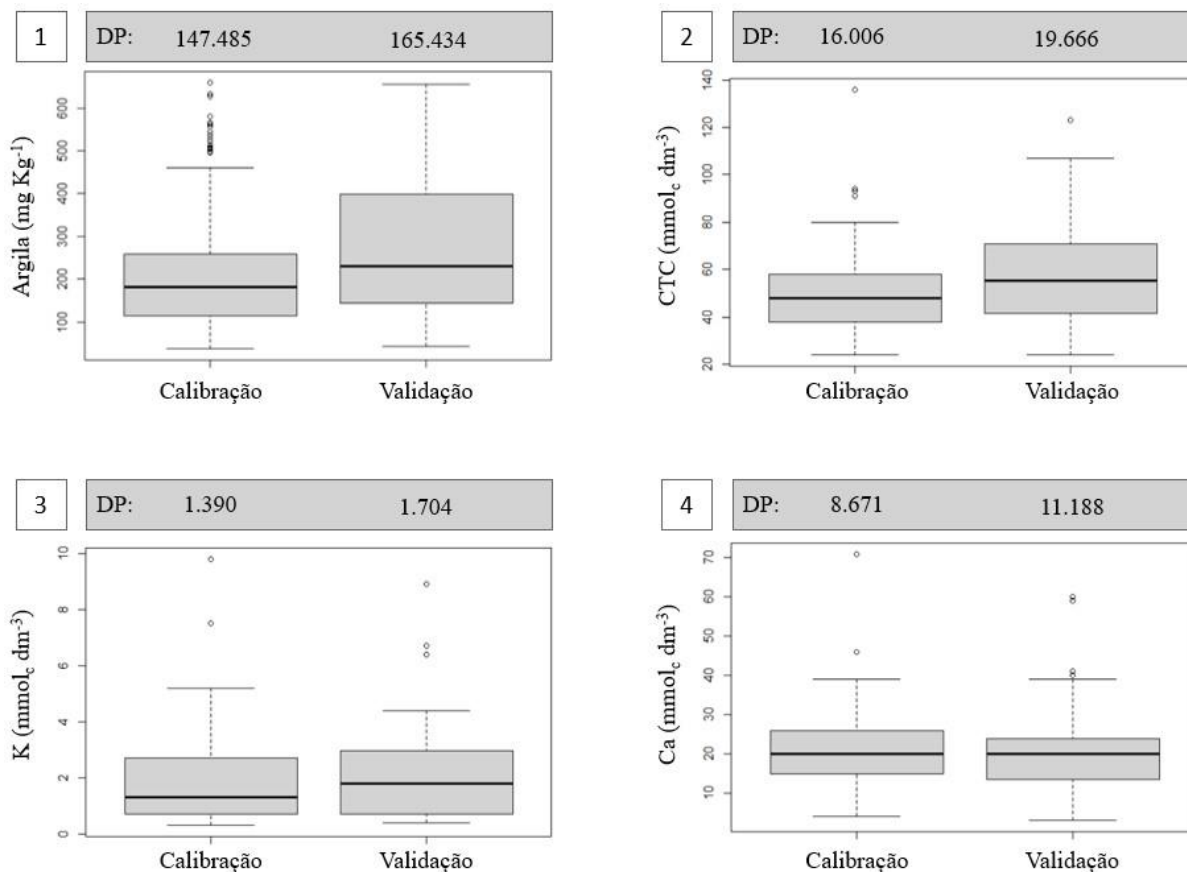




FIGURA 3. Estatística descritiva dos atributos de fertilidade através de gráficos Box plot para o conjunto de dados de calibração e validação, mostrando o desvio padrão (DP) e faixa de variação para os teores de argila (1), capacidade de troca catiônica (CTC) (2), e ex-K (3), ex-Ca (4). **Descriptive statistics of fertility attributes through Box plot graphics for the calibration and validation dataset, showing the standard deviation (SD) and range of variation for clay contents (1), cation exchange capacity (CTC) (2), and extractable K (3), Ca (4).**

A Tabela 2 mostra as correlações entre os atributos de fertilidade do solo e as linhas de emissão do espectro de XRF. Esses dados ajudam a entender por que as quantificações dos atributos de fertilidade são possíveis com o sensor de XRF. Por exemplo, a argila apresentou alta correlação com diversas linhas de emissão, com destaque para Compton-K $\alpha$  ( $r = -0,91$ ), Fe-K $\alpha$  ( $r = 0,90$ ), Ni-K $\alpha$  ( $r = -0,85$ ), Cu-K $\alpha$  ( $r = 0,80$ ), Thomson-L $\alpha$  ( $r = 0,80$ ), Thomson-K $\alpha$  ( $r = -0,77$ ) e Si-K $\alpha$  ( $r = -0,76$ ). O ex-Ca apresentou alta correlação com a linha Ca-K $\alpha$  ( $r = 0,71$ ), correlação moderada com o K-K $\alpha$  ( $r = 0,58$ ) e P-K $\alpha$  ( $r = 0,44$ ). Por outro lado, o ex-K apresentou correlações mais baixas com as linhas de emissão do XRF ( $-0,40 \leq r \leq 0,51$ ). Por fim, a CTC mostrou correlação moderada com várias linhas de emissão, entre elas a do Compton-K $\alpha$  ( $r = -0,65$ ), Zn-K $\alpha$  ( $r = 0,61$ ), Fe-K $\alpha$  ( $r = 0,58$ ) e Thomson-L $\alpha$  ( $r = 0,55$ ). Além das correlações típicas entre argila e as linhas de emissão do Fe, Si, Al e Ti (ANDRADE et al., 2020; BENEDET et al., 2020), observou-se nesse trabalho que as linhas de espalhamento Compton-K $\alpha$ , Thomson-K $\alpha$  e Thomson-L $\alpha$  apresentaram altas correlações com a argila (Tabela 2). A intensidade dessas linhas é inversamente proporcional ao número atômico (Z) médio da amostra (MELQUIADES et al., 2012). A relação inversa da argila com as linhas K $\alpha$  do Rh Compton e Thomson pode estar relacionada a maior presença de argilominerais com presença de Fe e Ti (e.g., goethita e hematita), o que fez o número atômico médio dessas amostras aumentarem. Por outro lado, amostras arenosas tendem a ter relação maior com minerais contendo Si (e.g., quartzo), elemento com número atômico ( $Z = 14$ ) inferior ao do Fe ( $Z = 26$ ) e Ti ( $Z = 22$ ). Possivelmente, essa constatação não foi observada para o Thomson-L $\alpha$ , pois a energia dessa linha (2,91 keV) está em uma região mais influenciada interferências espectrais (GALLHOFER et al., 2018), e.g., linha K $\alpha$  do Ar (2,95 keV), presente na atmosfera.

TABELA 2. Coeficiente de correlação de Pearson entre os atributos de fertilidade do solo e as linhas de emissão do XRF. **Pearson's correlation between soil fertility attributes and XRF emission lines.**

Linhas de emissão	Argila	ex-Ca	ex-K	CTC
Al-K $\alpha$	0,62	0,02	0,36	0,30
Si-K $\alpha$	-0,76	-0,20	-0,40	-0,54
P-K $\alpha$	-0,03	0,44	0,16	0,41
S-K $\alpha$	-0,31	-0,10	-0,16	-0,20
K-K $\alpha$	-0,13	0,58	0,31	0,45
Ca -K $\alpha$	-0,33	0,71	0,11	0,27
Ti-K $\alpha$	0,61	0,10	0,23	0,42
Cr-K $\alpha$	0,06	0,36	0,32	0,27
Mn-K $\alpha$	0,13	0,33	0,19	0,34
Fe-K $\alpha$	0,90	0,13	0,32	0,58
Ni-K $\alpha$	-0,85	-0,10	-0,29	-0,54
Cu-K $\alpha$	0,80	0,10	0,34	0,50
Zn-K $\alpha$	0,67	0,29	0,51	0,61
Zr-K $\alpha$	0,48	0,09	0,36	0,36
Thomson-K $\alpha$	-0,77	-0,19	-0,33	-0,54
Thomson-L $\alpha$	0,80	0,16	0,31	0,55
Compton- K $\alpha$	-0,91	-0,21	-0,37	-0,65

A Tabela 3 mostra os parâmetros de desempenho da calibração e validação dos modelos obtidos via regressão linear simples (RLS), múltipla (RLM) e por mínimos quadrados parciais (PLS). Observando o conjunto de calibração, de maneira geral, os maiores desempenhos foram obtidos com o método PLS, sendo o ex-Ca a única exceção a qual mostrou desempenho equiparável para ambas as técnicas multivariadas. Em todos os casos, a RLS apresentou desempenhos mais baixos que os modelos multivariados. A RLS apenas obteve predições satisfatórias para o ex-Ca (RPD = 1,5), o que enfatiza a necessidade de se utilizar modelos

multivariados para a predição de atributos de fertilidade do solo. Em suma, os modelos RLM e PLS apresentaram desempenhos excelentes para a argila (RPD de 3,9 para a RLM e de 4,1 para o PLS), bons para o ex-Ca (RPD de 2,3 para a RLM e de 2,2 para o PLS) e CTC (RPD de 2,5 para a RLM e de 2,7 para o PLS), e ruins para o ex-K (RPD = 1,2 para ambos). A vantagem da modelagem PLS, está na facilidade da implementação de uma rotina computacional, que colete e converta as contagens dos canais de energia em atributos de fertilidade do solo. Nesse caso, não há necessidade de realizar a seleção das linhas de emissão a serem utilizadas como variáveis explicativas. Por outro lado, ao utilizar o espectro inteiro é recomendado a utilização de métodos de pré-processamento espectral para otimização do desempenho preditivo do PLS (SANTOS et al., 2021), o que acaba inserindo uma etapa a mais no processo de calibração. Gráficos de dispersão relacionando os valores de referência dos atributos de fertilidade com os preditos pelos modelos PLS são apresentados na Figura 4. Verifica-se que a dispersão de pontos dos modelos de argila, ex-Ca e CTC apresentou comportamento linear, posicionada próxima a reta 1:1, corroborando com os desempenhos reportados na Tabela 3.

TABELA 3. Desempenho da calibração e validação dos modelos de predição utilizando regressão linear simples (RLS), múltipla (RLM) e por mínimos quadrados parciais (PLS) para atributos de fertilidade de solo. **Calibration and validation performance of prediction models using simple linear regression (RLS), multiple regression (RLM) and partial least squares (PLS) for soil fertility attributes.**

		Argila			ex-K <sup>1</sup>			ex-Ca <sup>1</sup>			CTC <sup>2</sup>		
		RLS <sup>3</sup>	RLM	PLS	RLS <sup>3</sup>	RLM	PLS	RLS <sup>3</sup>	RLM	PLS	RLS <sup>3</sup>	RLM	PLS
Calibração	R <sup>2</sup>	0,41	0,95	0,97	0,09	0,43	0,49	0,47	0,83	0,8	0,06	0,82	0,89
	RMSE	113,2	33,4	27,3	1,3	1	1	6,3	3,6	3,8	15,5	6,8	5,3
	RE	51,8	15,3	12,5	73,2	57,7	54,5	30,3	17,3	18,6	30,7	13,6	10,5
	RPD	1,3	4,4	5,4	1	1,3	1,4	1,4	2,4	2,2	1	2,3	3
	VL <sup>4</sup>	-	-	4	-	-	3	-	-	4	-	-	5
Validação	R <sup>2</sup>	0,3	0,93	0,94	0,11	0,3	0,32	0,57	0,82	0,8	0,12	0,84	0,86
	RMSE	141,2	42,1	40,4	1,6	1,4	1,4	7,3	5	5	19,7	8	7,3
	RE	51,6	15,4	14,8	77,2	66,9	66	35,2	23,8	24,2	34,6	14	12,9
	RPD	1,2	3,9	4,1	1	1,2	1,2	1,5	2,3	2,2	1	2,5	2,7

<sup>1</sup>Nutrientes extraíveis; <sup>2</sup>Capacidade de troca de cátions; <sup>3</sup>Os modelos de RLS utilizaram a linha de emissão Ti-Ka como variável preditora de argila, K-Ka para ex-K, Ca-Ka para ex-Ca e Ca-Ka para CTC nas regressões lineares simples; <sup>4</sup>Número de variáveis latentes utilizadas no modelo de PLS. Os valores de RPD foram apresentados em escala de cinza, destacando os valores mais altos.

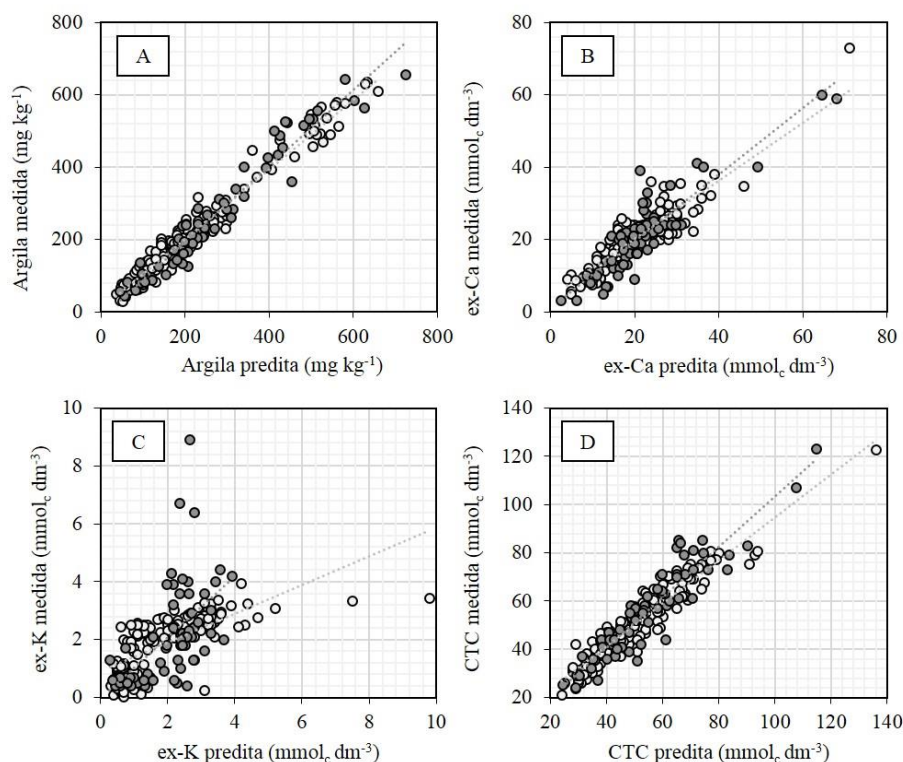


FIGURA 4. Gráficos de dispersão apresentando os valores preditos e medidos para a argila (A), ex-Ca (B), ex-K (C) e CTC (D) dos modelos PLS. As amostras em cinza claro e escuro são dos conjuntos de calibração e validação, respectivamente. **Scatter plots showing predicted and measured values for clay (A), ex-Ca (B), ex-K (C) and CTC (D) of PLS models. The samples in light and dark gray are of the calibration and validation data sets, respectively.**

Os desempenhos para predição dos atributos de fertilidade observados neste trabalho corroboram com o observado na literatura, sendo comum observar desempenho bons para predição de argila, ex-Ca e CTC e desempenhos variáveis para a predição de ex-K. Nesse contexto, Lima et al (2019) mostrou predições com desempenho alto ( $R^2 = 0,85$ ) para o diagnóstico de argila em amostras oriundas de solos do cerrado. Por sua vez, Andrade et al. (2020) mostrou desempenhos preditivos com  $R^2$  de 0,71 para ex-Ca e de 0,67 para ex-K. Em contrapartida, Teixeira et al. (2018) obteve desempenho ruim para determinações de ex-K, com valores de  $R^2$  variando de 0,04 a 0,12. Por fim, Silva et al., (2017), relatou resultados promissores para predição de CTC, com  $R^2$  variando de 0,86 a 0,87. Quanto ao pré-processamento de espectros utilizados de forma prévia à calibração do PLS, observamos que os métodos que combinaram centragem na média com algum tipo de escalonamento apresentaram melhores desempenhos para todos os atributos (Tabela 4), e.g., no modelo de predição de argila, o RMSEP foi de 62,9 para 42,3  $\text{mg kg}^{-1}$  ao combinar a centragem na média com o escalonamento pelo desvio padrão. O escalonamento pelo desvio padrão foi utilizado nos modelos de ex-Ca e CTC e o escalonamento interquartil nos de argila e ex-K. Os métodos de escalonamentos geralmente não são recomendados para dados contínuos (e.g. espectros), pois na presença de espalhamentos ou ruídos, estes ganham a mesma importância que os picos (FERREIRA, 2015). No entanto, esse comportamento não foi observado nesta pesquisa, o que deve ser atribuído a dois fatores: (i) o escalonamento contribui para que as linhas de emissão, com amplitudes distintas, tenham pesos iguais no modelo; (ii) o espalhamento de fundo dos espectros XRF podem estar correlacionados com a fração orgânica do material (BASTOS et al. 2012). Em suma, os resultados do presente trabalho permitem sugerir o PLS para a calibração de modelos preditivos de atributos de fertilidade do solo usando dados espectrais do sensor XRF. Diferente do que têm sido tradicionalmente feito por trabalhos publicados nesta temática, a abordagem sugerida pelo presente trabalho — i.e., calibrações utilizando os espectros associados à técnica PLS — não emprega pacotes de aquisição de dados pré-programados e, conseqüentemente, permite avançarmos em direção a construção de bibliotecas espectrais, bem como propor otimizações de condições instrumentais que viabilizem utilizações rápidas do XRF diretamente no campo (e.g., aquisição de espectros utilizando tempo de leitura reduzido, tal como 5 s). Esses avanços são fundamentais para expandirmos as aplicações do sensor XRF no contexto da Agricultura

de Precisão. Por fim, vale a pena mencionar que embora o PLS tenha se destacado frente às demais técnicas de modelagem preditiva avaliadas neste trabalho, é recomendável que futuros trabalhos explorem abordagens usando técnicas não lineares de modelagens computacionais (e.g., florestas randômicas e redes neurais artificiais), especialmente em bancos de dados com números de amostras maiores.

TABELA 4. Métodos de pré-processamento testados nos modelos PLS e os respectivos valores de RMSEP. **Pre-processing methods tested in PLS models and the respective RMSEP values.**

Métodos de pré-processamento	RMSEP			
	Argila (4 VL)	ex-Ca (4 VL)	ex-K (3 VL)	CTC (5 VL)
Espectro bruto	61,9	9,40	1,62	12,6
Centragem na média	62,9	9,42	1,61	15,7
Centragem na média + escalonamento (desvio padrão)	42,3	5,06	1,40	7,3
Centragem na média + escalonamento (intervalo interquartil)	40,4	5,13	1,39	7,4

**CONCLUSÃO:** O sensor XRF apresentou desempenhos satisfatórios ( $RPD > 2,0$ ) para a quantificação de argila, ex-Ca e CTC, sendo o ex-K o único a apresentar desempenho ruim ( $RPD < 1,4$ ), independente da técnica de modelagem utilizada. Os modelos multivariados se mostraram claramente superiores aos modelos utilizando regressão linear simples. Comparando os modelos de regressão linear múltipla (RLM) e de regressão por mínimos quadrados parciais (PLS), observou-se desempenhos melhores para o PLS para a predição de argila ( $RPD$  de 3,9 para a RLM e de 4,1 para o PLS) e CTC ( $RPD$  de 2,5 para a RLM e de 2,7 para o PLS). A predição de ex-Ca obteve desempenho semelhante com ambas as técnicas multivariadas ( $RPD$  de 2,3 para a RLM e de 2,2 para o PLS). Os resultados observados pelo presente trabalho permitem sugerir o PLS como técnica de modelagem ótima para calibração de modelos preditivos de atributos de fertilidade do solo usando dados espectrais do sensor XRF. Por fim, recomenda-se que futuros trabalhos que busquem implementar modelagens preditivas otimizadas em bancos de dados maiores, também avaliem o desempenho de modelos computacionais (e.g., redes neurais artificiais e florestas randômicas).

#### AGRADECIMENTOS:

Agradecemos à empresa Ribersolo Laboratório de Análises Agrícolas, pela disponibilização das amostras e análises de referência, bem como à FAPESP pelo suporte financeiro ao T.R.T. (processo nº 2020/16670-9).

#### 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, 113960, 2020.
- BASTOS, R. O.; MELQUIADES, F. L.; BIASI, G. E. V. Correction for the effect of soil moisture on in situ XRF analysis using low-energy background. **X-RAY Spectrometry**. v. 41, p. 304-307, 2012.
- BENEDET, L.; FARIA, W.M.; SILVA, S.H.G.; MANCINI, M.; DEMATTÊ, J.A.M.; GUILHERME, L.R.G.; CURI, N. Soil texture prediction using portable X-ray fluorescence spectrometry and visible near-infrared diffuse reflectance spectroscopy. **Geoderma**, v.376, p.114553, 2020.
- CHANG, C.W.; LAIRD, D.A.; MAUSBACH, M.J.; HORSBURGH, C.R. Near infrared reflectance spectroscopy–principal components regression analyses of soil properties. **Soil Science Society of America Journal**, v.65, n.2, p.480-490, 2001.
- FERREIRA, M. M. C. Quimiometria: Conceitos, Métodos e Aplicações. Campinas, SP: Editora da Unicamp, 2015.

- GALLHOFER, D.; LOTTERMOSER, B.G. The influence of spectral interferences on critical element determination with portable X-ray fluorescence (pXRF). **Minerals**, v.8, p. 320, 2018.
- GREDILLA, A.; VALLEJUELO, S.F.O.; ELEJOSTE, N.; 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 in Analytical Chemistry**, v.76, p.30-39, 2016.
- KENNARD, R.W.; STONE, L.A. Computer aided design of experiments. **Technometrics**, v.11, n.1, p.137-148, 1969.
- 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.
- MELQUIADES, F. L.; BORTOLETO, G. G.; MARCHIORI, L.F.S.; BUENO, M. I. M. S. Direct determination of sugar cane quality parameters by X-ray spectrometry and multivariate analysis. **Journal of Agricultural and Food Chemistry**, v. 60, n. 43, p. 10755–10761, 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.
- SANTOS, F.R.; OLIVEIRA, J.F.; BONA, E.; BARBOSA, G.M.; MELQUIADES, F.L. Evaluation of pre-processing and variable selection on energy dispersive X-ray fluorescence spectral data with partial least square regression: A case of study for soil organic carbon prediction. **Spectrochimica Acta Part B-Atomic Spectroscopy**, v. 175, p.106016, 2021.
- 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.
- SILVA, S.H.G.; TEIXEIRA, A.F.D.S.; MENEZES, M.D.D.; GUILHERME, L.R.G.; MOREIRA, F.M.D.S.; CURI, N. Multiple linear regression and random forest to predict and map soil properties using data from portable X-ray fluorescence spectrometer (pXRF). **Ciênc. Agrotec.**, v. 41, p. 648–664, 2017.
- 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.; 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.
- 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.



# DESEMPENHO DE SENSOR XRF PARA PREDIÇÃO DE TEXTURA, pH, ALUMÍNIO E MATÉRIA ORGÂNICA EM SOLOS TROPICAIS DE SÃO PAULO

Marcos Mantelli Ragagnin<sup>1</sup>; Gabriel Gava<sup>2</sup>; Inácio Duarte Vieira<sup>2</sup>; Carlos Roberto Pinheiro Júnior<sup>3</sup>; Tiago Rodrigues Tavares<sup>4</sup>

<sup>1</sup>Estudante, Graduando - Laboratório de Agricultura de Precisão, ESALQ, USP, Piracicaba-SP. marcosmragagnin@usp.br / (64) 9 9959-8206; <sup>2</sup>Estudante, Graduando - Laboratório de Agricultura de Precisão, ESALQ, USP, Piracicaba-SP; <sup>3</sup>Engenheiro agrônomo, Doutorando - Departamento de Solos, UFRRJ, Seropédica-RJ; <sup>4</sup>Engenheiro agrônomo, Pesquisador Pós-Doc - Laboratório de Instrumentação Nuclear, CENA, USP, Piracicaba-SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Nos últimos anos o grande avanço das geotecnologias e das técnicas de sensoriamento próximo do solo tem permitido um avanço na caracterização espacial de atributos de fertilidade do solo, buscando uma rápida obtenção de resultado, com baixo custo e sem uso de reagentes químicos. Nesse sentido, o objetivo desse estudo foi avaliar o desempenho de um sensor fluorescência de raios X (XRF) para a predição dos teores de areia, silte e argila, valores de pH, Al<sup>3+</sup> trocável e conteúdo de matéria orgânica (MO) em solos tropicais do estado de São Paulo. Para isso, foram utilizadas 214 amostras de solo coletadas em diferentes profundidades em cinco diferentes áreas agrícolas. A partir dos resultados obtidos, foram gerados modelos preditivos calibrados e validados utilizando regressão linear múltipla. O desempenho do sensor de XRF foi considerado excelente para predição de argila (RPD = 4,11 e R<sup>2</sup> = 0,95) e areia (RPD = 3,84 e R<sup>2</sup> = 0,94); razoáveis para silte (RPD = 1,67 e R<sup>2</sup> = 0,71), pH (RPD = 1,46 e R<sup>2</sup> = 0,53) e MO (RPD = 1,98 e R<sup>2</sup> = 0,76); e ruim para predição de Al<sup>3+</sup> (RPD = 0,89 e R<sup>2</sup> = 0,02). Os resultados do nosso estudo indicam o potencial de utilização da técnica XRF associada a *machine learning* como método alternativo de determinação da textura, pH, e MO de solos tropicais, embora haja necessidade da exploração de conjuntos de dados maiores e mais abrangentes geograficamente.

**PALAVRAS-CHAVE:** Modelagem preditiva; diagnóstico de fertilidade; laboratório híbridos

## XRF SENSOR PERFORMANCE FOR PREDICTING TEXTURE, PH, ALUMINIUM AND ORGANIC MATTER IN TROPICAL SOILS OF SÃO PAULO

**ABSTRACT:** In recent years, the great advance of geotechnologies and proximal sensing techniques has allowed an advance in the spatial characterization of soil fertility attributes, seeking to obtain results quickly, at low cost, and without using chemical reagents. The objective of this study was to evaluate the performance of an X-ray fluorescence (XRF) sensor for the prediction of sand, silt and clay contents, pH values, exchangeable Al<sup>3+</sup>, and organic matter (OM) content in tropical soils from the state of São Paulo. For this, 214 soil samples collected at different depths in five different agricultural areas were used. From the results obtained, predictive models were calibrated and validated using multiple linear regression. The XRF sensor performance was rated excellent for clay (RPD = 4.11 and R<sup>2</sup> = 0.95) and sand (RPD = 3.84 and R<sup>2</sup> = 0.94) predictions; reasonable for silt (RPD = 1.67 and R<sup>2</sup> = 0.71), pH (RPD = 1.46 and R<sup>2</sup> = 0.53), and MO (RPD = 1.98 and R<sup>2</sup> = 0.76); and poor for Al<sup>3+</sup> prediction (RPD = 0.89 and R<sup>2</sup> = 0.02). The results of our study indicate the potential for using the XRF technique associated with machine learning as an alternative method for determining texture, pH, and OM in tropical soils. Despite our promising results, there is a need for exploring larger and more geographically comprehensive datasets.

**KEYWORDS:** Predictive modeling; fertility diagnosis; hybrid laboratories

**INTRODUÇÃO:** A agricultura de precisão e geoestatística trouxeram conceitos importantes para o entendimento da variabilidade espacial da fertilidade do solo, tal como a necessidade de uma densidade amostral ótima para representação da variação desses atributos em forma de mapas. Estudos têm convergido para recomendação de uma malha amostral de pelo menos uma amostra por hectare para caracterização

especial de atributos de fertilidade (NANNI et al., 2011; CHERUBIN et al., 2015). Do ponto de vista prático, a implantação dessa densidade amostral enfrenta dificuldades, tendo em vista os desafios da logística para coleta de amostras e, principalmente, com o maior custo relacionado às análises laboratoriais (McBRATNEY et al., 2003; DEMATTÊ et al., 2015). A partir desse dilema, uma solução tradicionalmente proposta para evitar custos excessivos com análises de laboratório é a utilização de técnicas de sensoriamento próximo do solo (SPS), as quais se configuram como métodos de análise mais rápidos, práticos, que não usam reagentes químicos e que são compatíveis com aplicações *in situ* utilizando equipamentos portáteis (ADAMCHUK et al., 2004; BREVIK et al., 2016). Dentre as diversas técnicas abrangidas pelo SPS, podemos destacar o uso da espectroscopia de fluorescência de raios X (XRF) (Nawar et al., 2019), que vem ganhando atenção dos pesquisadores e do mercado nos últimos anos. Um dos motivos desse interesse é sua capacidade de quantificar, de forma multi-elementar, a composição química dos constituintes do solo (e.g., teores totais de Si, Fe, Al, K, P e Ca), permitindo inferir com bons desempenhos, tanto sobre atributos texturais, quanto sobre atributos químicos da fertilidade do solo (e.g., macronutrientes, capacidade de troca de cátions, etc.) (MOLIN; TAVARES, 2019). No Brasil, Lima et al. (2019) avaliaram os solos da região do Triângulo Mineiro e Alto Paranaíba (ambos no estado de Minas Gerais) e obtiveram predições promissoras para argila ( $R^2 = 0,87$ ), areia ( $R^2 = 0,85$ ) e matéria orgânica do solo (MO) ( $R^2 = 0,61$ ) usando espectrometria XRF e métodos lineares de regressão. Por sua vez, o trabalho de Andrade et al. (2020) apresentou desempenhos baixos para predição de  $Al^{3+}$  a partir de amostras coletadas nos estados da Bahia, Espírito Santo e leste de Minas Gerais, com  $R^2$  oscilando entre 0,21 e 0,41, ao utilizarem modelos preditivos lineares, e uma variação entre 0,18 e 0,47, ao utilizarem o modelo não linear de Floresta Randômica. Silva et al. (2017), trabalhando com amostras coletadas em Minas Gerais, obtiveram predições com desempenho bastante variável, de modo que os valores de  $R^2$  oscilaram entre 0,00 e 0,58 para predições de  $Al^{3+}$ ; entre 0,00 e 0,59 para predições de MO, e entre 0,05 e 0,82 para predições de pH. Por sua vez, Tavares et al. (2020a) observaram predições satisfatórias para argila ( $R^2 \geq 0,88$ ) e MO ( $R^2 \geq 0,61$ ) e ruins para pH ( $R^2 \leq 0,38$ ), ao utilizar um banco de dados misto com amostras de uma área do estado de São Paulo e outra do estado de Mato Grosso. Apesar dos avanços obtidos nos últimos anos para aplicação do XRF como um método analítico da fertilidade do solo, estudos mais abrangentes em solos de São Paulo ainda são incipientes. Esta pesquisa visa preencher esta lacuna, avançando o uso de espectroscopia XRF para avaliar os principais atributos de fertilidade em solos tropicais. Neste sentido, o presente trabalho avaliou o desempenho de um sensor XRF portátil combinado a um modelo de machine learning simples e generalista para predição de argila, areia, silte, MO,  $Al^{3+}$  e pH em solos de cinco áreas agrícolas.

**MATERIAIS E MÉTODOS:** Ao todo foram utilizadas 214 amostras de solo coletadas em cinco áreas agrícolas localizadas nos municípios de Monte Azul (Área G), Patrocínio Paulista (Área H), Coronel Macedo (Área I), Catanduva (Área J) e Torrinha (Área K), todos no estado de São Paulo. Compuseram o banco de dados um total de 6 amostras da área G, 45 da H, 50 da I, 87 da J e 26 da K. As amostras foram coletadas em três profundidades distintas, de 0-20, 20-40 e 80-100 cm, totalizando respectivamente 157, 28 e 29 amostras em cada uma dessas profundidades. Os teores de argila, areia, silte, os valores de pH ( $CaCl_2$ ), o  $Al^{3+}$  trocável e o conteúdo MO foram quantificados em um laboratório comercial de análises agrícolas, de acordo com os métodos preconizados por Teixeira et al. (2017). Espectros de XRF foram obtidos utilizando um equipamento portátil de XRF por energia dispersiva (Tracer III-SD, Bruker AXS, Madison, WI, EUA). O tubo de raios X do equipamento foi configurado para operar com 35 kV de tensão e 7  $\mu A$  de corrente, com análises sendo conduzidas sob pressão atmosférica (i.e., sem uso de vácuo ou atmosfera de argônio), sem uso de filtros e com tempo de permanência de 30 s. De cada um dos 214 frascos contendo as amostras foram coletadas sub amostras, as quais foram colocadas em cubetas contendo na parte inferior um plástico feito de um tipo de material específico que permitisse a passagem dos raio-X sem que houvesse perturbações. Cada cubeta foi preenchida até mais ou menos sua metade a amostra de solo correspondente, para só aí serem levadas para a leitura no sensor XRF. Para cada uma das sub amostras foram realizadas duas análises de trinta segundos cada, através do equipamento, girando cada uma entre a primeira e segunda amostragem em cerca de 180°, visando-se obter a máxima variabilidade contida na sub amostra. Todo o procedimento foi realizado em bancada, visando-se preservar ao máximo as características da amostra durante as análises. Após as análises, as sub amostras foram ainda preservadas durante certo tempo até a análise dos dados, para no caso de haver erros estes pudessem ser corrigidos refazendo-se a análise com a mesma subamostra. No que tange à modelagem, foram ajustados modelos preditivos de regressão linear múltipla (RLM), os quais foram calibrados utilizando um subconjunto com 70% dos dados ( $n = 150$ ) e validados nos 30% restantes ( $n = 64$ ). Essa divisão foi realizada através do método de Kennard-Stone (KENNARD; STONE, 1969), aplicados sobre os atributos de

fertilidade. A qualidade dos modelos foi avaliada pelo coeficiente de determinação ( $R^2$ ), raiz do erro quadrático médio (RMSE), razão do desempenho pela distância interquartil (RPIQ) (BELLON-MAUREL et al., 2010) e o desvio porcentual relativo (RPD) (CHANG et al., 2001). Os modelos foram implementados através do software The Unscrambler (Camo AS, Oslo, Noruega). A interpretação dos valores de RPD foi realizada seguindo as seguintes classes de interpretação: modelos excelentes ( $RPD \geq 3,0$ ), modelos bons ( $3,0 > RPD \geq 2,0$ ), modelos razoáveis ( $2,0 > RPD \geq 1,4$ ) e modelos ruins ( $RPD < 1,4$ ).

**RESULTADOS E DISCUSSÃO:** A Tabela 1 apresenta, para o conjunto de calibração e validação, a estatística descritiva dos atributos de fertilidade do solo utilizados como referência para os modelos preditivos. É possível observar que, de maneira geral, as amostras avaliadas apresentaram alto gradiente de variação desses atributos, com argila oscilando entre 37 e 660 g kg<sup>-1</sup>, areia entre 169 e 942 g kg<sup>-1</sup>, pH entre 3,90 e 8,70 e Al<sup>3+</sup> entre 0,30 e 24,30 mmolc dm<sup>-3</sup>. Os teores de MO e silte apresentaram amplitude um pouco menor, (MO oscilando entre 2,00 e 30,00 g dm<sup>-3</sup> e silte entre 13,00 e 270,00 g kg<sup>-1</sup>), porém condizente aos teores comumente observados em solos tropicais. Para todos os atributos avaliados, tanto o conjunto de calibração, quanto o de validação apresentaram amplitude e variação comparáveis (Tabela 1), característica desejada para avaliação do desempenho dos modelos (STENBERG et al., 2010).

TABELA 1. Estatística descritiva, para o conjunto de dados de calibração e validação, sobre os atributos de fertilidade do solo. **Descriptive statistics, for the calibration and validation data set, about soil fertility attributes.**

Atributos	Argila	Silte	Areia total	pH	Matéria Orgânica	Alumínio
	----- g kg <sup>-1</sup> -----				g dm <sup>-3</sup>	mmolc dm <sup>-3</sup>
Calibração (n=148)						
Min	37,00	15,00	169,00	3,90	2,00	0,30
1º quartil	112,00	48,00	645,00	4,90	9,00	0,50
Mediana	175,00	76,00	746,00	5,10	12,00	0,70
3º quartil	245,50	101,00	827,00	5,60	16,00	1,40
Max	660,00	270,00	941,00	8,70	30,00	24,30
DV*	141,32	45,68	176,65	0,68	4,81	2,33
Validação (n=64)						
Min	45,00	13,00	172,00	4,10	4,00	0,30
Q1	153,50	68,00	387,50	4,70	8,50	0,70
Mediana	252,00	115,00	624,00	4,90	14,00	1,20
Q3	447,50	163,50	761,50	5,25	18,00	2,35
Max	643,00	263,00	942,00	6,80	27,00	9,50
DV*	168,83	60,91	213,39	0,52	5,74	1,71

DV\* representa os valores do desvio padrão dos dados.

Observamos correlações fortes ( $r > 0,75$  ou  $r < -0,75$ ) dos teores de argila e areia com as linhas de emissão Si-K $\alpha$ , Fe-K $\alpha$ , Ni-K $\alpha$  e as linhas de espalhamento Thomson-K $\alpha$ , Thomson-La e Compton-K $\alpha$  do Rh. Por sua vez,



os teores de silte apresentaram correlação forte apenas com a linha de espalhamento Compton-K $\alpha$ . O pH, MO e Al<sup>3+</sup> não apresentaram correlações fortes com as linhas de emissão do XRF. A maior correlação observada para o pH foi com a linha Ca-K $\alpha$  ( $r = 0,63$ ) e, para a MO, foram com o Fe-K $\alpha$ , Ni-K $\alpha$ , Cu-K $\alpha$ , Rh Thomson-L $\alpha$  e Rh Compton-K $\alpha$  ( $0,50 < r < 0,58$ , com  $r$  representado em módulo). O Al<sup>3+</sup> somente apresentou correlações fracas, com  $r$  oscilando entre -0,31 e 0,21. O espalhamento de energia provindo da fonte de raio X se relaciona de forma indireta com o número atômico ( $Z$ ) médio da amostra (JENKINS, 2012). Em amostras de solo secas, isso pode refletir teores de MO, i.e., quanto maior a concentração de MO (a qual tipicamente apresenta elementos com baixo número atômico, e.g., C, H e O), menor será o número atômico médio e maior será o espalhamento (MORONA et al., 2017). Por outro lado, em alguns grupos e amostras as linhas de espalhamento também podem se relacionar com a textura do solo, e.g., conjuntos de amostras com altos teores de areia podem apresentar uma maior proporção de Si ( $Z = 14$ ) (proveniente do mineral quartzo) que Fe ( $Z = 26$ ) e Ti ( $Z = 22$ ) (provenientes dos minerais de argila, tal como hematita e goethita), o que contribui para reduzir o número atômico médio de amostras arenosas e, conseqüentemente, aumentar a intensidade de seu espalhamento. Essa relação entre textura e o espalhamento foi observada no presente trabalho para as linhas de espalhamento Thomson-K $\alpha$  e Compton-K $\alpha$  do Rh[mr1] [T2], as quais apresentaram correlação positiva com os teores de areia e negativa com os teores de argila. Por fim, também mencionamos que a informação presente nas linhas de espalhamento também pode ser utilizada para mitigação do efeito matriz presente em outras linhas de emissão (LU et al., 2022), servindo como informação complementar em modelos preditivos que envolvem amostras com variabilidade de matrizes, tal como o conjunto de amostras do presente trabalho.

TABELA 2. Coeficiente de correlação de Pearson ( $r$ ) entre as linhas de emissão do XRF e os atributos de fertilidade. **Pearson's correlation between XRF emission lines and soil fertility attributes.**

Linhas de emissão	Argila	Silte	Areia	pH	Matéria Orgânica	Alumínio
Al-K $\alpha$	0.62	0.38	-0.59	-0.22	0.18	0.14
Si-K $\alpha$	-0.76	-0.61	0.76	0.33	-0.28	-0.17
P-K $\alpha$	-0.03	0.14	-0.01	0.01	0.10	0.03
S-K $\alpha$	-0.31	-0.33	0.33	0.20	0.16	-0.09
K-K $\alpha$	-0.13	0.24	0.04	-0.03	-0.43	0.15
Ca -K $\alpha$	-0.33	-0.23	0.32	0.63	-0.11	-0.31
Ti-K $\alpha$	0.61	0.53	-0.63	-0.33	0.37	0.13
Cr-K $\alpha$	0.06	0.11	-0.07	-0.07	-0.40	-0.05
Mn-K $\alpha$	0.13	0.35	-0.19	-0.11	-0.15	0.02
Fe-K $\alpha$	0.90	0.70	-0.90	-0.37	0.57	0.21
Ni-K $\alpha$	-0.85	-0.72	0.87	0.39	-0.55	-0.19
Cu-K $\alpha$	0.80	0.64	-0.81	-0.30	0.56	0.16
Zn-K $\alpha$	0.67	0.62	-0.69	-0.26	0.36	0.19
Zr-K $\alpha$	0.48	0.57	-0.54	-0.38	0.06	0.16
Rh-Thomson K $\alpha$	-0.77	-0.64	0.78	0.26	-0.41	-0.14
Rh-Thomson L $\alpha$	0.80	0.63	-0.80	-0.29	0.56	0.15

-0.91            -0.76            0.92            0.38            -0.52            -0.24

Rh-Compton  $K\alpha$

Verificou-se desempenhos excelentes para argila (RPD = 4,11 e  $R^2 = 0,95$ ) e areia (RPD = 3,84 e  $R^2 = 0,94$ ) e desempenho razoáveis para silte (RPD = 1,67 e  $R^2 = 0,71$ ), pH (RPD = 1,46 e  $R^2 = 0,53$ ) e MO (RPD = 1,98 e  $R^2 = 0,76$ ). Por sua vez, o  $Al^{3+}$  apresentou desempenho ruim (RPD = 0,89 e  $R^2 = 0,02$ ). As dispersões apresentadas na Figura 1, corroboram com esses desempenhos, mostrando uma distribuição linear de pontos bem próximos à reta 1:1 para argila e areia; distribuições lineares mais afastadas da reta 1:1 para silte, pH e MO; e a ausência de dispersão linear para o modelo de  $Al^{3+}$ . No que diz respeito os demais parâmetros verificou-se que a argila (RPIQ = 3,73 e RMSE= 34,35), areia (RPIQ = 4,71 e RMSE= 20,39), silte (RPIQ = 2,50 e RMSE=36,84), e Ph (RPIQ = 2,72 e RMSE=2,57), apresentaram um excelente desempenho. Por sua vez, a predição de MO apresentou desempenho razoável (RPIQ = 1,71 e RMSE=2,57) e a de  $Al^{3+}$  apresentou desempenho baixo (RPIQ = 0,49 e RMSE=1,85).

**TABELA 3. Desempenhos preditivos do sensor XRF para os atributos de fertilidade estudados. XRF sensor predictive performances for studied fertility soil attributes.**

Parâmetro	Argila	Silte	Areia	pH	Matéria Orgânica	Alumínio[mr3] [T4]
Calibração (n=148)						
R <sup>2</sup>	0.94	0.95	0.75	0.71	0.54	0.37
RMSE	34.35	36.84	20.39	2.57	0.46	1.85
RE	16.32	5.20	25.01	20.08	8.83	130.63
RPD	4.11	4.80	2.24	1.87	1.47	1.26
RPIQ	3.73	4.71	2.50	2.72	1.51	0.49
Validação (n=64)						
R <sup>2</sup>	0.95	0.94	0.71	0.76	0.53	0.02
RMSE	37.86	55.60	36.51	2.90	0.36	1.92
RE	12.89	9.46	30.79	20.93	7.06	108.22
RPD	4.46	3.84	1.67	1.98	1.46	0.89
RPIQ	7.18	6.35	2.52	3.11	1.41	0.83

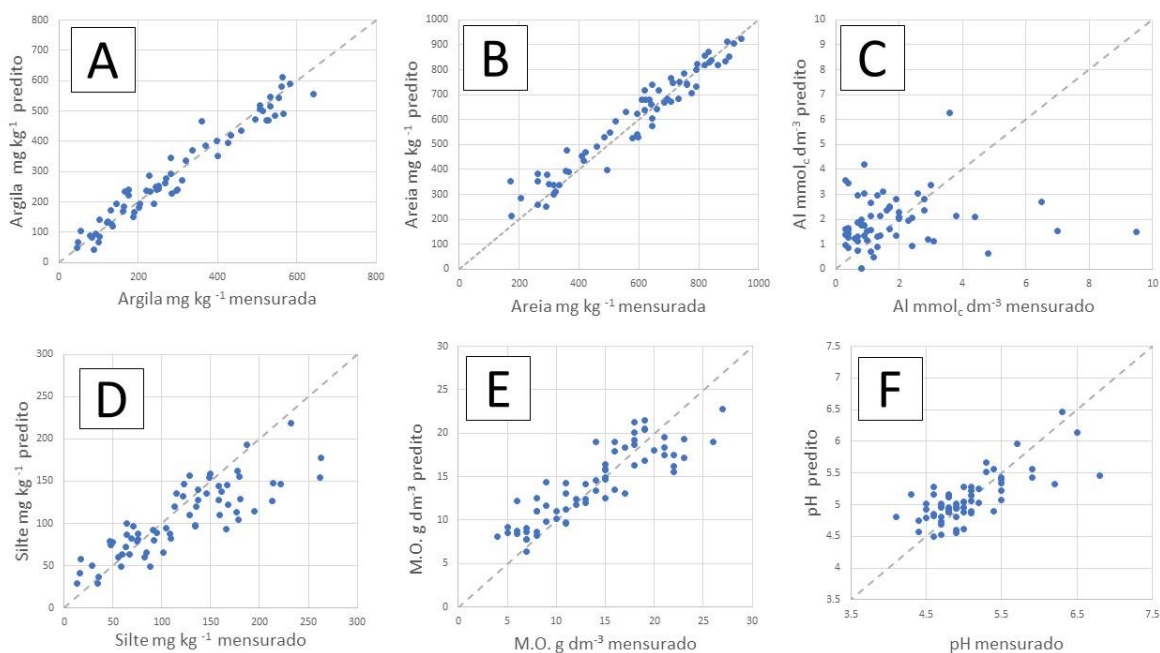


Figura 1. Gráficos de dispersão (para o conjunto de validação,  $n = 64$ ) relacionando os valores preditos e medidos de argila (A), areia (B),  $Al^{3+}$  (C), silte (D), M.O. (Matéria orgânica) (E) e pH (F). **Scatter plots (for the validation set,  $n = 64$ ) of measured versus predicted clay (A), sand (B),  $Al^{3+}$  (C), silt (D), O.M. (Organic matter) (E), and pH (F).**

Os modelos de argila e areia apresentaram a linha de emissão Ti-K $\alpha$  e Compton-K $\alpha$  como variáveis mais importantes. Isso corrobora com o observado por Tavares et al. (2020a) ao prever argila utilizando RLM em amostras do estado de São Paulo e Mato Grosso. Por sua vez, Lima et al. (2019) utilizando RLM associada ao método de seleção de variáveis *Stepwise*, obteve previsões de textura satisfatórias utilizando as linhas de emissão do Fe, Si, Ti, V e Zr; os autores não consideraram a região de espalhamento em sua modelagem. O Ti está relacionado aos minerais de argila de solos tropicais (e.g., hematita e goethita), pois podem estar presentes na estrutura destes óxidos de ferro como substitutos isomórficos do Fe (SCHÄEFER et al., 2008). Por sua vez, as linhas de espalhamento podem ter obtido importância no presente conjunto de amostras por terem contribuído para a mitigação do efeito matriz. Efeito desta natureza foi observado por Tavares et al. (2020b) ao prever teores disponíveis de Ca utilizando linhas de emissão normalizadas pelo espalhamento Compton. O modelo de silte apresentou o K-K $\alpha$  como variável mais importante, enquanto que para a previsão do pH a variável de maior importância foi o Ca-K $\alpha$ . Esse resultado se deve ao fato do  $Ca^{2+}$  ser o principal cátion básico do complexo de troca do solo, nesse sentido, quanto maior o teor de  $Ca^{2+}$  menor será a contribuição de cátion ácidos como  $Al^{3+}$  e  $H^+$ , o que reflete diretamente nos valores de pH. Os modelos de MO apresentaram como variáveis mais importantes as linhas de emissão do S-K $\alpha$  e a do Ca-K $\alpha$ , o que pode estar relacionado a presença destes elementos na estrutura dos compostos orgânicos. Por fim, comenta-se que modelos ruins para previsão de  $Al^{3+}$  já foram reportados por Andrade et al. (2020) que associaram a baixa relação entre os teores totais e trocáveis de Al em solos tropicais — devido à alta influência da mineralogia e manejo nessa relação — como o principal fator limitante para essa previsão. Além desse fator, também podemos associar a baixa energia de fluorescência do Al-K $\alpha$  (1,48 keV), que acaba sendo uma linha de emissão bastante influenciada pelas variações de matriz do conjunto amostral. Os desempenhos preditivos observados neste trabalho para determinação de argila, areia e MO corroboram com o observado por trabalhos de Lima et al. (2019), Tavares et al. (2020a) e Silva et al. (2017), os quais reportaram  $R^2$  superiores a 0,84 para atributos texturais e  $R^2$  oscilando entre 0,29 e 0,72 para MO. As previsões de pH foram superiores às reportadas por Tavares et al. (2020a), que obtiveram  $R^2 < 0,39$ , inferiores às reportadas por Teixeira et al. (2018), que mostraram  $R^2$  superiores a 0,84. As previsões de pH foram semelhantes às observadas por Silva et al. (2017), que apresentaram  $R^2$  entre 0,51 e 0,89. Por sua vez, os modelos ruins de  $Al^{3+}$  também corroboram com os desempenhos ruins já reportados por Teixeira et al. (2018) e Andrade et al. (2020).

TABELA 4. Coeficientes beta padronizados das variáveis do XRF utilizadas nos modelos preditivos, os quais podem ser utilizados para inferir sobre a importância das diferentes variáveis explicativas em cada modelo. As

unidades utilizadas foram:  $\text{g kg}^{-1}$  para textura,  $\text{g dm}^{-3}$  para MO (matéria orgânica) e  $\text{mmolc dm}^{-3}$  para alumínio. **Standardized beta coefficients of the XRF variables used in the predictive models, which can be used to infer about the importance of the different explanatory variables in each model. Units used were:  $\text{g kg}^{-1}$  for texture,  $\text{g dm}^{-3}$  for soil organic matter and  $\text{mmolc dm}^{-3}$  for aluminum.**

Linhas de emissão	Argila	Silte	Areia	pH	Matéria Orgânica	Alumínio
Al-K $\alpha$	1.06	0.06	-0.92	1.34	-1.62	1.60
Si-K $\alpha$	-0.53	0.83	-0.02	0.89	0.44	-0.10
P-K $\alpha$	-0.81	1.06	0.09	-1.65	1.84	0.88
S-K $\alpha$	0.09	-2.05	1.07	0.62	3.38	-0.98
K-K $\alpha$	-1.46	5.24	-1.71	-1.58	-0.87	4.49
Ca -K $\alpha$	0.18	-1.46	0.67	8.83	3.36	-4.59
Ti-K $\alpha$	-8.56	-1.37	7.92	-0.99	-0.62	-0.13
Cr-K $\alpha$	1.03	-1.53	0.00	-0.60	-2.19	-3.03
Mn-K $\alpha$	-4.10	-0.91	3.94	0.69	-5.06	-0.01
Fe-K $\alpha$	3.67	0.93	-3.59	-0.49	2.46	0.20
Ni-K $\alpha$	1.21	-0.69	-0.62	-0.94	-1.75	2.77
Cu-K $\alpha$	0.61	1.19	-1.18	-0.49	2.02	0.37
Zn-K $\alpha$	2.21	1.01	-2.41	-0.97	1.38	2.00
Zr-K $\alpha$	1.29	2.60	-2.53	-0.02	2.05	-2.12
Rh-Thomson K $\alpha$	0.06	-0.95	0.48	-0.52	0.09	1.38
Rh-Thomson L $\alpha$	-0.36	0.81	-0.15	-0.76	1.29	1.16
Rh-Compton K $\alpha$	-5.05	-0.59	4.55	-0.51	1.67	-0.86

**CONCLUSÃO:** O sensor de fluorescência de raios X (XRF) apresentou desempenhos excelentes para predição de argila (RPD = 4,11 e  $R^2 = 0,95$ ) e areia (RPD = 3,84 e  $R^2 = 0,94$ ), desempenho razoáveis para silte (RPD = 1,67 e  $R^2 = 0,71$ ), pH (RPD = 1,46 e  $R^2 = 0,53$ ) e MO (RPD = 1,98 e  $R^2 = 0,76$ ) e desempenho ruim para predição de  $\text{Al}^{3+}$  (RPD = 0,89 e  $R^2 = 0,02$ ) em amostras de solo provenientes de cinco áreas agrícolas diferentes, todas localizadas no estado de São Paulo. Os resultados obtidos por este trabalho corroboram com os demais trabalhos publicados na literatura e indicam o potencial de associar a técnica XRF com modelos de aprendizado de máquina para o avanço deste sensor como um método alternativo para a determinação de atributos texturais, pH e MO em solos tropicais brasileiros. Por fim, sugere-se que futuros trabalhos explorem conjuntos de dados maiores e mais abrangentes geograficamente.

#### AGRADECIMENTOS:

Agradecemos à empresa Ribersolo Laboratório de Análises Agrícolas, pela disponibilização das amostras e análises de referência, bem como à FAPESP pelo suporte financeiro ao T.R.T. (processo nº 2020/16670-9).

## REFERÊNCIAS

- ADAMCHUK V.I.; HUMMEL J.W.; MORGAN M.T.; UPADHYAYA S.K. (2004) On-the-go soil sensors for precision agriculture. **Computers and electronics in agriculture**, 44(1): 71-91.
- ANDRADE, R. et al. Prediction of soil fertility via portable X-ray fluorescence (pXRF) spectrometry and soil texture in the Brazilian Coastal Plains. **Geoderma**, v. 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..
- BREVIK E.C.; CALZOLARI C.; MILLER B.A.; PEREIRA P.; KABALA C.; BAUMGARTEN A.; JORDÁN A. Soil mapping, classification, and pedologic modeling: History and future directions. **Geoderma**, 264: 256-274, 2016.
- 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, n.2, p.480-490, 2001.
- 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**, 50(2): 168-177, 2015.
- JENKINS, R. X-Ray Fluorescence Spectrometry; **John Wiley & Sons**: Hoboken, NJ, USA; p. 232; 2012.
- LIMA, Tatiane Melo et al. Elemental analysis of Cerrado agricultural soils via portable X-ray fluorescence spectrometry: Inferences for soil fertility assessment. **Geoderma**, v. 353, p. 264-272, 2019.
- DEMATTÊ J.A.M.; ALVES M.R.; GALLO B.C.; FONGARO C.T.; SOUZA A.B.; ROMERO DJ, SATO MV (2015) Hyperspectral remote sensing as an alternative to estimate soil attributes. **Revista Ciencia Agronomica**, 46(2): 223–232.
- FUNARI, L.M.; **Motivações e métodos de previsão de demanda aplicados a eventos**. Pouso Alegre, 2021
- GREDILLA A.; VALLEJUELO S.F.O.; ELEJOSTE N.; 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 in Analytical Chemistry**, 76: 30-39, 2016.
- KENNARD, R.W.; STONE, L.A. computer aided design of experiments. **technometrics**, v.11, n.1, p.137-148, 1969.
- LU, J.; GUO, J.; WEI, Q.; TANG, X.; LAN, T.; HOU, Y.; ZHAO, X. A matrix effect correction method for portable x-ray fluorescence data. **Applied sciences**, v.12, n.2, p.568, 2022.
- MC BRATNEY A.B.; SANTOS M.M.; MINASNY B. On digital soil mapping. **Geoderma**, 117(1-2): 3-52 2003.
- 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.

MORONA, F.; SANTOS, F.R.; BRINATTI, A.M.; MELQUIADES, F.L. Quick analysis of organic matter in soil by energy-dispersive X-ray fluorescence and multivariate analysis. **Appl. Radiat. Isotopes**, v.130, p.13–20, 2017.

NANNI M.R.; POVH F.P.; DEMATTÊ J.A.M.; OLIVEIRA R.B.D.; CHICATI M.L.; CEZAR E. Optimum size in grid soil sampling for variable-rate application in site-specific management. **Scientia Agricola**, 68(3): 386-392, 2011.

NAWAR S.; DELBECQUE N.; DECLERCQ Y.; SMEDT P.; FINKE P.; VERDOODT A.; MEIRVENNE M.V.; MOUAZEN A.M. Can spectral analyses improve measurement of key soil fertility parameters with X-ray fluorescence spectrometry?. **Geoderma**, 350: 29-39, 2019.

SCHÄEFER, C.E.G.R.; FABRIS, J.D.; KER, J.C. Minerals in the clay fraction of Brazilian latosols (oxisols): A review. **Clay Miner.** 43, 137–154; 2008.

SILVA, S.H.G. et al. Multiple linear regression and random forest to predict and map soil properties using data from portable X-ray fluorescence spectrometer (pXRF). **Ciência e Agrotecnologia**, v. 41, p. 648-664, 2017.

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.; 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, 2020a.

TAVARES, T.R.; MOUAZEN, A.M.; ALVES, E.E.N.; DOS SANTOS, F.R.; MELQUIADES, F.L.; PEREIRA DE CARVALHO, H.W.; MOLIN, J.P. Assessing soil key fertility attributes using a portable X-ray fluorescence: A simple method to overcome matrix effect. **Agronomy**, 10(6), p.787, 2020.

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. **Ciência e Agrotecnologia**, v.42, n.5, p.501-512, 2018.

TEIXEIRA, P.C.; DONAGEMMA, G.K.; FONTANA, A.; TEIXEIRA, W.G. **Manual de métodos de análise de solo**. Embrapa, Brasília, 2017.

# DESEMPENHO DE SENSOR XRF PARA PREDIÇÃO DE MACRONUTRIENTES, CAPACIDADE DE TROCA DE CÁTIONS E SATURAÇÃO DE BASES EM SOLOS TROPICAIS

Gabriel Toledo Marques<sup>1</sup>; Tiago Rodrigues Tavares<sup>2</sup>; Thainara Rabelo da Silva<sup>3</sup>; Carlos Roberto Pinheiro Junior<sup>4</sup>; José Paulo Molin<sup>5</sup>

<sup>1</sup>Graduando em Engenharia Agrônômica, Graduando - Grupo de Mecanização e Agricultura de Precisão, ESALQ, USP, Piracicaba - SP. gabriel.toledomarques@usp.br / (19) 9 9832-0491; <sup>2</sup>Engenheiro Agrônomo, Pesquisador Pós-Doc - Lab de Instrumentação Nuclear, CENA, USP, Piracicaba - SP; <sup>3</sup>Engenheira Agrícola, Mestranda - Departamento de Engenharia de Biossistemas, ESALQ, USP, Piracicaba - SP; <sup>4</sup>Engenheiro Agrônomo, Doutorando - Departamento de Solos, UFRRJ, Seropédica - RJ; <sup>5</sup>Engenheiro Agrícola, Professor - Departamento de Engenharia de Biossistemas, ESALQ, USP, Piracicaba - SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Sensores de fluorescência de raios X (XRF) são ferramentas de sensoriamento próximo do solo que têm apresentado resultados promissores para predição de atributos químicos de fertilidade, porém pesquisas dessa natureza ainda são incipientes em solos tropicais. Este trabalho objetivou a avaliação do desempenho de um sensor de XRF para a predição de nutrientes extraíveis (ex-P, ex-Ca, ex-K e ex-Mg), capacidade de troca de cátions (CTC) e saturação de bases (V%) em um banco de dados abrangente vindos de solos tropicais. Foi utilizado um sensor portátil de XRF para aquisição de dados espectrais, os quais foram utilizados como variáveis independentes (variáveis X). Os atributos de fertilidade do solo foram avaliados em um laboratório comercial de fertilidade e foram utilizados como referência (variável Y) para a calibração de modelos via regressão linear múltipla. Os resultados mostraram desempenhos bons para ex-Ca (RPD = 2,14 e  $R^2 = 0,78$ ) e CTC (RPD = 2,03 e  $R^2 = 0,78$ ), razoáveis para ex-Mg (RPD = 1,81 e  $R^2 = 0,77$ ) e V% (RPD = 1,49 e  $R^2 = 0,56$ ) e ruins para ex-P (RPD = 1,20 e  $R^2 = 0,37$ ) e ex-K (RPD = 1,20 e  $R^2 = 0,37$ ). Comparações entre o resultados deste trabalho com os reportados na literatura indicam que o XRF apresenta desempenho oscilante em função do conjunto amostral utilizado, trabalhos futuros devem criar estratégias para superar essa limitação. De todas maneiras, é evidente o potencial da técnica para predição de atributos químicos de fertilidade em solos tropicais.

**PALAVRAS-CHAVE:** Modelagem preditiva; Análise da fertilidade do solo; Sensoriamento próximo ao solo

## PERFORMANCE OF XRF SENSOR FOR PREDICTION OF MACRONUTRIENTS, CATION EXCHANGE CAPACITY AND BASE SATURATION IN TROPICAL SOILS

**ABSTRACT:** X-ray fluorescence sensors (XRF) are a proximal soil sensing tool that have shown promising results for predicting chemical fertility attributes, but research of this nature is still incipient in tropical soils. This work aimed to evaluate the performance of an XRF sensor for the prediction of extractable nutrients (ex-P, ex-Ca, ex-K and ex-Mg), cation exchange capacity (CEC) and base saturation (V%) in a comprehensive database from tropical soils. A portable XRF sensor was used to acquire spectral data, which were used as independent variables (X variables). The soil fertility attributes were evaluated in a commercial fertility laboratory and were used as reference (variable Y) for the calibration of models via multiple linear regression. The results showed good performances for ex-Ca (RPD = 2.14 and  $R^2 = 0.78$ ) and CEC (RPD = 2.03 and  $R^2 = 0.78$ ), reasonable for ex-Mg (RPD = 1.81 and  $R^2 = 0.77$ ) and V% (RPD = 1.49 and  $R^2 = 0.56$ ) and poor for ex-P (RPD = 1.20 and  $R^2 = 0.37$ ) and ex-K (RPD = 1.20 and  $R^2 = 0.37$ ). Comparisons between the results of this work and those reported in the literature indicate that XRF presents oscillating performance depending on the sample set used, future work should create strategies to overcome this limitation. In any case, the potential of the technique for predicting chemical fertility attributes in tropical soils is evident

**KEYWORDS:** Predictive modeling; Soil fertility tests; Proximal soil sensing

**INTRODUÇÃO:** A busca por métodos rápidos, versáteis e precisos para a análise da fertilidade do solo é um tópico proeminente dentro da agricultura de precisão desde sua concepção (KHOSLA; ALLEY, 1999). Diversas técnicas de sensoriamento já foram propostas e testadas para avaliações práticas da fertilidade do solo de forma a incrementar a densidade espacial de análises, e.g., sensores de condutividade elétrica aparente, sensores de espectroscopia de reflectância difusa no visível e infravermelho (vis-NIR), entre outros (VISCARRA ROSSEL et al., 2011). Recentemente sensores XRF têm sido considerados uma ferramenta importante dentro do sensoriamento próximo do solo e da agricultura de precisão (MOLIN; TAVARES, 2019). A técnica de XRF é capaz de caracterizar a composição de elementos químicos presentes nas amostras de solo, permitindo assim melhores inferências sobre atributos químicos de interesse agrônômico do que outras técnicas utilizadas no sensoriamento do solo, e.g., sensores vis-NIR (O'ROURKE et al., 2016). Em solos de regiões temperadas, Javadi et al. (2021) mostraram predições satisfatórias ( $R^2 > 0,80$ ) para ex-Mg e ex-Ca e O'Rourke et al. (2016) apresentaram bons desempenhos ( $R^2 > 0,75$ ) para CTC. Além disso, sensores XRF tem potencial para evoluir em direção a aplicações diretamente no campo, uma vez que suas leituras são menos afetadas pela umidade do solo que técnicas tradicionalmente aplicadas in situ (e.g., sensores vis-NIR), além de também ser bastante flexível quanto ao preparo de amostra (TAVARES et al., 2019). Apesar disso, pesquisas em solos tropicais brasileiros são incipientes, sendo poucos os trabalhos que exploram bancos de dados abrangentes, i.e., com diversidade geográfica e número robusto de amostras. Neste contexto, visando contribuir para a compreensão do potencial do XRF para diagnósticos de atributos de fertilidade em solos tropicais, o objetivo deste trabalho é calibrar e avaliar modelos preditivos utilizando dados de XRF para determinação de teores de ex-K, ex-Ca, ex-Mg, ex-P, V% e CTC em solos provenientes de oito áreas agrícolas diferentes.

**MATERIAIS E MÉTODOS:** Foram utilizadas 372 amostras de solo oriundas de oito áreas agrícolas, situadas nos municípios paulistas de Limeira, Cabrália Paulista, Dois Córregos, Monte Azul, Patrocínio Paulista, Coronel Macedo, Catanduva e Torrinha. Estas amostras foram coletadas em diferentes profundidades, em superfície (0-20 cm) e em subsuperfície (20-40 e 80-100 cm), e posteriormente secas ao ar, destorroadas e peneiradas (< 2 mm), para obtenção da fração terra fina seca ao ar, a partir das quais foram realizadas as análises químicas e espectroscópicas. O sensoriamento foi realizado utilizando um equipamento portátil de XRF (Tracer-III-SD, Bruker AXS, Madison, WI, EUA). O tubo de raios X do equipamento foi configurado para operar com voltagem e corrente de 35 kV e 7 $\mu$ A, respectivamente (TAVARES et al., 2020). O tempo de aquisição foi de 30 s para cada replicata. Como porta amostras utilizou-se cubetas plásticas com fundo selado com filme de polipropileno de 4  $\mu$ m de espessura (SPEX, Metuchen, NJ, USA), comportando cerca de 10 g de cada amostra. Cada amostra foi analisada em duplicata, realizadas em posições diferentes da amostra. Os espectros XRF foram obtidos através do processo de deconvolução utilizando o Artax® (Bruker AXS, Madison, WI, EUA), obtendo-se a intensidade das linhas de emissão do Al-K $\alpha$ , Si-K $\alpha$ , P-K $\alpha$ , S-K $\alpha$ , K-K $\alpha$ , Ca-K $\alpha$ , Ti-K $\alpha$ , Cr-K $\alpha$ , Mn-K $\alpha$ , Fe-K $\alpha$ , Ni-K $\alpha$ , Cu-K $\alpha$ , Zn-K $\alpha$ , Zr-K $\alpha$ , Thomson-K $\alpha$ , Thomson-La e Compton-K $\alpha$ , todas em contagens por segundo (cps). As análises de referência foram conduzidas em um laboratório comercial de fertilidade do solo seguindo os métodos descritos por Raij et al., (2001). Utilizou-se resina extratora para determinação de ex-P e mehlich-2 para ex-K, ex-Ca e ex-Mg. A acidez potencial do solo (H + Al) foi quantificada através do método de pH em solução tampão (SMP) e utilizada para cálculo da CTC, a qual corresponde à soma da acidez potencial do solo com a soma das bases (ex-Ca + ex-Mg + ex-K). A saturação percentual de bases (V%) foi calculada pela razão entre a soma das bases com a CTC. Para o processamento dos dados foi utilizado o software The Unscrambler (CAMO Software, Oslo 1984, Noruega). O conjunto total de amostras (n = 372) foi dividido em dois grupos pelo algoritmo Kennard-Stone (KENNARD; STONE, 1969), o conjunto de calibração com 70% dos dados (n=263) e o de validação com 30% (n=105). A estatística descritiva foi aplicada para verificar a variabilidade dos conjuntos de calibração e validação. Em seguida, o modelo foi criado utilizando a regressão linear múltipla para cada atributo de fertilidade de solo. As 17 linhas de emissão do XRF, mencionadas acima, foram utilizadas como variáveis explicativas para todos os modelos. O desempenho dos modelos foi avaliado com base nos valores de coeficiente de determinação ( $R^2$ ), raiz do erro quadrático médio (RMSE) e desvio da predição residual (do inglês, *Residual Prediction Deviation* - RPD) (CHANG et al., 2001). Utilizou-se as seguintes classes RPD para interpretação dos modelos: RPD  $\geq 3,0$  para modelos excelentes;  $3,0 > RPD \geq 2,0$  para modelos bons;  $2,0 > RPD \geq 1,4$  para modelos razoáveis e RPD < 1,4 para modelos ruins.

**RESULTADOS E DISCUSSÃO:** Na Tabela 1 está disposta a estatística descritiva, para os conjuntos calibração e validação, dos atributos de solo estudados. Nesta tabela, pode-se comprovar a efetividade do



método Kennard-Stone em garantir grupos de amostras com estatística descritiva similares, visto que todos os atributos no conjunto de validação apresentaram um desvio padrão e amplitude comparáveis com o de calibração. Além disso, a ampla variação dos atributos nestes conjuntos de dados (CV variando entre 30 e 110%) mostra a alta variabilidade presente nas amostras destas oito áreas agrícolas distintas.

TABELA 1: Estatística descritiva mostrando o valor máximo (Max), mínimo (Min), média, mediana, primeiro quartil (Q1), terceiro quartil (Q3), desvio padrão (DP) e coeficiente de variação (CV) para os atributos do solo dos conjuntos de calibração e validação. **Descriptive statistics showing the maximum (Max), minimum (Min), mean, median, first quartile (Q1), third quartile (Q3), standard deviation (SD) and coefficient of variation (CV) for the soil attributes of the calibration and validation sets.**

Calibração (n = 263)						
Atributos	ex-P	ex-Ca	ex-Mg	ex-K	CTC	V%
Max	150.00	144.00	40.00	11.60	220.00	86.00
Min	1.00	2.00	1.00	0.30	20.00	17.00
Média	13.11	17.04	6.09	1.57	46.76	50.81
Mediana	10.00	16.00	5.00	1.20	44.00	51.00
Q1	6.00	10.00	4.00	0.60	33.00	39.50
Q3	17.00	21.00	7.00	2.15	55.00	63.00
DP	14.46	13.08	4.08	1.28	20.88	15.12
CV	110%	77%	67%	81%	45%	30%
Validação (n = 105)						
Max	59.00	71.00	36.00	9.80	136.00	86.00
Min	1.00	1.00	1.00	0.30	22.00	12.00
Média	19.84	20.10	7.53	2.22	54.70	52.79
Mediana	17.00	19.00	6.00	2.00	52.00	53.00
Q1	9.00	13.00	5.00	0.80	40.00	41.00
Q3	28.00	25.00	9.00	3.10	68.00	67.00
DP	14.18	11.63	5.62	1.76	21.15	18.48
CV	72%	58%	75%	80%	39%	35%

A Tabela 2 apresenta a correlação entre as linhas de emissão do XRF e os atributos de fertilidade estudados. De maneira geral, os macronutrientes ex-K, ex-Ca e ex-P apresentaram maior correlação com a linha de emissão de seu respectivo elemento, e.g., a maior correlação do ex-P foi com o P-K $\alpha$  ( $r = 0,46$ ), a maior correlação do ex-Ca foi com o Ca-K $\alpha$  ( $r = 0,80$ ) e a segunda maior correlação do ex-K foi com o K-K $\alpha$  ( $r = 0,41$ ). Possivelmente, em nível local (i.e., avaliado área individuais) essas correlações se apresentem mais fortes, pois haveria menor efeito da variação da composição mineralógica ou de práticas de manejo (e.g., aplicação recente de calcário ou pó de rocha) em cada área, e conseqüentemente, menor variação da relação entre o teor total e disponível dos elementos avaliados. O ex-Mg apresentou  $r \geq 0,60$  com as linhas de emissão do Ca e do K. Equipamentos portáteis de XRF geralmente não conseguem detectar a fluorescência do Mg-K $\alpha$ ,

pois este elemento tem energia de fluorescência baixa (1,25 keV) e seus teores corriqueiramente encontrados em solos tropicais ficam abaixo do limite de detecção da técnica (WEINDORF; CHAKRABORTY, 2020). V% apresentou correlação mais alta ( $r = 0,64$ ) com a linha do Ca-K $\alpha$ . A CTC apresentou correlação de 0,51 com o Ca-K $\alpha$ , 0,49 com o K-K $\alpha$  e de 0,45 com o P-K $\alpha$ , sendo que sua correlação mais forte ( $r = 0,65$ ) foi com o Zn-K $\alpha$ . As relações entre atributos de fertilidade e as linhas de emissão do XRF observadas neste trabalho corroboram com o observado em outras pesquisas conduzidas em solos tropicais (LIMA et al., 2019; ANDRADE et al., 2020; TAVARES et al., 2020)

TABELA 2: Correlação entre as linhas de emissão do XRF e os atributos de fertilidade do solo. **Correlation between each XRF emission line and the soil fertility attributes.**

Atributos	ex-P	ex-Ca	ex-Mg	ex-K	CTC	V%
Al-K $\alpha$	-0,06	0,01	0,05	0,20	0,26	-0,13
Si-K $\alpha$	0,02	-0,18	-0,25	-0,30	-0,47	0,12
P-K $\alpha$	0,46	0,52	0,49	0,23	0,45	0,30
S-K $\alpha$	0,13	0,01	-0,06	-0,08	-0,12	0,17
K-K $\alpha$	0,08	0,56	0,69	0,41	0,49	0,42
Ca-K $\alpha$	0,40	0,80	0,60	0,25	0,51	0,64
Ti-K $\alpha$	-0,04	0,17	0,23	0,21	0,43	-0,17
Cr-K $\alpha$	0,02	0,27	0,37	0,31	0,28	0,29
Mn-K $\alpha$	0,05	0,45	0,53	0,33	0,49	0,19
Fe-K $\alpha$	0,01	0,14	0,20	0,27	0,51	-0,26
Ni-K $\alpha$	0,02	-0,12	-0,18	-0,25	-0,48	0,30
Cu-K $\alpha$	0,17	0,23	0,21	0,36	0,55	-0,19
Zn-K $\alpha$	0,21	0,36	0,38	0,51	0,65	-0,09
Zr-K $\alpha$	-0,01	0,08	0,18	0,29	0,34	-0,16
Rh Thom. K-K $\alpha$	-0,03	-0,14	-0,20	-0,27	-0,43	0,20
Rh Thom. L-K $\alpha$	0,04	0,18	0,22	0,28	0,50	-0,17
Rh Com. K-K $\alpha$	-0,03	-0,20	-0,26	-0,33	-0,57	0,24

TABELA 3: Importância das variáveis explicativas para cada modelo de predição. Correlação de Pearson para cada linha de emissão do XRF para cada variável resposta. **Importance of X-variables for each predictive model. Pearson correlation for each XRF emission line for each response variable**

Atributos	ex-P	ex-Ca	ex-Mg	ex-K	CTC	V%
Al_K $\alpha$	-1,34	0,24	-0,60	-0,32	0,64	0,32
Si_K $\alpha$	0,04	0,48	-0,78	-1,23	0,50	-0,49

P_K $\alpha$	5,83	-1,01	-0,40	-0,18	-0,18	-1,48
S_K $\alpha$	0,31	0,23	0,78	1,17	1,15	1,29
K_K $\alpha$	-1,39	4,49	4,91	4,26	5,63	0,79
Ca_K $\alpha$	4,13	30,85	15,61	1,39	19,30	10,86
Ti_K $\alpha$	-2,29	-3,86	-2,97	-1,94	-4,71	-1,70
Cr_K $\alpha$	1,59	2,24	1,91	-0,07	-0,58	4,66
Mn_K $\alpha$	-2,31	-0,27	0,48	-0,58	-1,17	-0,37
Fe_K $\alpha$	-0,67	-0,41	1,82	-2,19	0,27	-0,32
Ni_K $\alpha$	1,00	-1,05	-1,01	0,12	-0,88	1,02
Cu_K $\alpha$	2,33	0,65	-1,20	3,87	2,27	-2,01
Zn_K $\alpha$	2,22	0,67	1,35	4,78	4,20	-2,44
Zr_K $\alpha$	1,19	1,17	1,22	-0,25	2,13	-1,88
Rh_Thom_K_K $\alpha$	0,03	-0,04	-1,05	0,35	0,48	0,29
Rh_Thom_L_K $\alpha$	1,09	1,58	0,01	2,19	2,14	1,86
Rh_Com_K_K $\alpha$	-1,14	-2,27	0,44	-1,19	-2,96	-0,95

A Figura 1 mostra os gráficos de dispersão que representam o desempenho dos modelos preditivos de ex-P, ex-Ca, ex-Mg, ex-K, CTC e V% com seus respectivos indicadores de desempenho  $R^2$ , RMSE e RPD. Os piores desempenhos preditivos foram observados para P-ex e K-ex, ambos com RPD inferiores a 1,40 e  $R^2$  inferiores a 0,40, indicando modelos com desempenho ruim. Modelos razoáveis foram obtidos para Mg-ex (RPD = 1,81 e  $R^2 = 0,77$ ) e V% (RPD = 1,49 e  $R^2 = 0,56$ ), enquanto que modelos bons foram observados para Ca-ex (RPD = 2,14 e  $R^2 = 0,78$ ) e CTC (RPD = 2,03 e  $R^2 = 0,78$ ). De maneira geral, as variáveis de maior importância para cada um dos modelos (Tabela 3) corroboraram com as variáveis que já haviam apresentado maior correlação com cada atributo do solo (Tabela 2). Os modelos de ex-P, ex-Ca e ex-K apresentaram suas respectivas linhas de emissão (P-K $\alpha$ , Ca-K $\alpha$  e K-K $\alpha$ ) como variáveis mais importantes e os modelos de CTC, V% e ex-Mg utilizaram a linha Ca-K $\alpha$  como variável de maior importância.

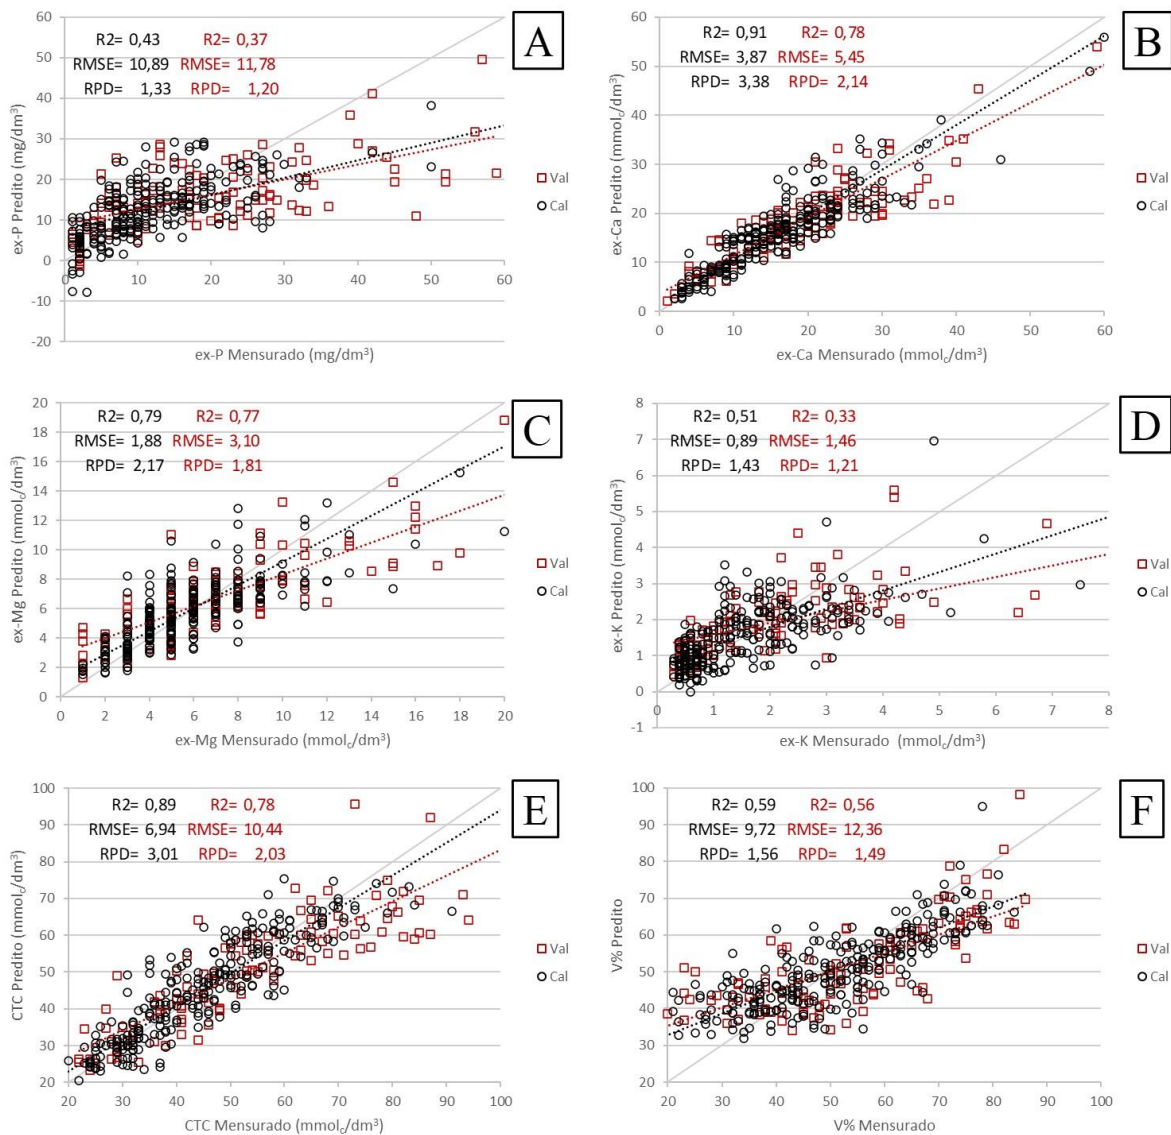


FIGURA 1: Gráficos de dispersão (dos conjuntos de calibração e validação) relacionando os valores preditos e medidos de ex-P (A), ex-Ca (B), ex-Mg (C), ex-K (D), CTC (E) e V% (F), obtidos via modelos de regressão linear múltipla **Scatter plot (for the calibration and validation dataset) of measured versus predicted ex-P (A), ex-Ca (B), ex-Mg (C), ex-K (D), CTC (E), and V% (F), which were obtained using multiple linear regression.**

Ao comparar o desempenho obtido pelo presente trabalho com outros resultados reportados na literatura, observa-se que o desempenho do XRF para predição de atributos químicos é bastante oscilante. Kaniu et al. (2012) utilizando um XRF de bancada, analisaram amostras providas de duas áreas agrícolas no Kenya e apresentaram modelos de ex-P e ex-Mg com  $R^2$  acima de 0,90; ambos superaram o desempenho observado no presente trabalho, especialmente o modelo de ex-P. Tavares et al. (2020) obtiveram modelos ruins para ex-P, de forma semelhante ao observado pelo presente trabalho. Por outro lado, os autores reportaram desempenhos excelentes para modelos de V% e ex-K, com  $R^2$  de 0,95 e 0,80, respectivamente. Ainda, para a predição de ex-K, estudos conduzidos por Silva et al. (2017) e Andrade et al. (2020) mostraram desempenho satisfatório, com  $R^2$  de 0,81 e 0,67, respectivamente. Em contraste, Teixeira et al. (2018) relataram modelos preditivos ruins para ex-K ( $0,04 \leq R^2 \leq 0,12$ ) usando amostras de solo adquiridas em áreas com diferentes usos do solo. Um comportamento semelhante também é observado para o ex-Ca ao comparar os resultados de diferentes trabalhos publicados sobre solos tropicais brasileiros (Silva et al., 2017; Teixeira et al., 2018; Lima et al., 2019; Silva et al., 2019; Andrade et al., 2020; Tavares et al., 2020), com  $R^2$  oscilando entre 0,71 e 0,90. Essa variação no desempenho de modelos preditivos reportados por diferentes trabalhos indica a complexidade da relação entre teores totais e atributos de fertilidade do solo. Por outro lado, também é evidente a capacidade do XRF de inferir de forma acurada sobre alguns atributos químicos do solo, tal como observado para ex-Ca e CTC

neste trabalho. Neste sentido, é necessário entender as características das amostras que afetam a diluição da acurácia do XRF (e.g., tipo de mineralogia, manejo, etc) para que seja possível estabelecer diretrizes para o desenvolvimento de bibliotecas espectrais. Ao agrupar amostras com características semelhantes e que não são compatíveis com análises via XRF será possível estabelecer uma estratégia que as desconsidere para ser avaliada via sensoriamento. Uma forma para isso seria estabelecer um modelo classificatório, a ser implementado de forma prévia ao modelo preditivo, que indique a possibilidade ou não de avaliação daquela amostra pelas vias do sensoriamento.

**CONCLUSÃO:** Os modelos preditivos utilizando dados do sensor XRF associados a regressão linear múltipla, calibrados e validados com um conjunto amostral composto por solos oriundos de oito áreas agrícolas do estado de São Paulo, apresentaram desempenhos bons para ex-Ca (RPD = 2,14 e  $R^2 = 0,78$ ) e CTC (RPD = 2,03 e  $R^2 = 0,78$ ), razoáveis para ex-Mg (RPD = 1,81 e  $R^2 = 0,77$ ) e V% (RPD = 1,49 e  $R^2 = 0,56$ ) e ruins para ex-P (RPD = 1,20 e  $R^2 = 0,37$ ) e ex-K (RPD = 1,20 e  $R^2 = 0,37$ ). Comparações dos desempenhos obtidos neste trabalho com os observados na literatura mostram uma alta variação de desempenho para atributos químicos, indicando a necessidade de entender mais a fundo as causas dessa variação para que possam ser desenvolvidas estratégias de modelagem robustas.

#### **AGRADECIMENTOS:**

Agradecemos à empresa Ribersolo Laboratório de Análises Agrícolas, pela disponibilização das amostras e análises de referência, bem como à FAPESP pelo suporte financeiro ao T.R.T. (processo nº 2020/16670-9).

#### **REFERÊNCIAS**

- ANDRADE, R.; FARIA, W.M.; SILVA, S.H.G.; CHAKRABORTY, S.; WEINDORF, D.C.; MESQUITA, L.F.; GUILHERME, L.R.G.; CURTI, N. Prediction of soil fertility via portable X-ray fluorescence (pXRF) spectrometry and soil texture in the Brazilian coastal plains. **Geoderma**, v.357, p.113960, 2020.
- 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, n.2, p.480-490, 2001.
- JAVADI, S.H.; MOUAZEN, A.M. Data Fusion of XRF and Vis-NIR Using Outer Product Analysis, Granger-Ramanathan, and Least Squares for Prediction of Key Soil Attributes. **Remote Sensing**. 2021
- KANIU, M. I. et al. 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.
- KENNARD, R.W.; STONE, L.A. Computer aided design of experiments. **Technometrics**, v.11, n.1, p.137-148, 1969.
- KHOSLA, R.; ALLEY, M.M. Soil-specific nitrogen management on Mid-atlantic coastal plain soils. **Better Crop**, 83(3), 6-7, 1999.
- LIMA, T.M., WEINDORF D., CURTI N. 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.
- O'ROURKE, S.M., STOCKMANN, U., HOLDEN, N.M., MCBRATNEY, A.B. AND MINASNY, B. An assessment of model averaging to improve predictive power of portable vis-NIR and XRF for the determination of agronomic soil properties. **Geoderma**, 279, pp.31-44. 2016

- RAIJ, B. van; ANDRADE, J.C. de; CANTARELLA, H.; QUAGGIO, J.A. **Análise Química para Avaliação da Fertilidade de Solos Tropicais**. Campinas, Instituto Agronômico, 285p. 2001
- SILVA, E.A., WEINDORF, D.C., SILVA, S.H., RIBEIRO, B.T., POGGERE, G.C., CARVALHO, T.S., GONCALVES, M.G., GUILHERME, L.R. AND CURI, N. Advances in tropical soil characterization via portable X-ray fluorescence spectrometry. **Pedosphere**, 29(4), pp.468-482., 2019
- SILVA, S.H.G., TEIXEIRA, A.F.D.S., MENEZES, M.D.D., GUILHERME, L.R.G., MOREIRA, F.M.D.S. AND CURI, N., Multiple linear regression and random forest to predict and map soil properties using data from portable X-ray fluorescence spectrometer (pXRF). **Ciência e Agrotecnologia**, 41(6), pp.648-664. 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, n.6, p.963, 2020.
- TAVARES, T.R., NUNES, L.C., ALVES, E.E.N., ALMEIDA, E.D., MALDANER, L.F., KRUG, F.J., CARVALHO, H.W.P.D. AND MOLIN, J.P. Simplifying sample preparation for soil fertility analysis by X-ray fluorescence spectrometry. **Sensors**, 19(23), p.5066, 2019
- TEIXEIRA, A.F.D.S., WEINDORF, D.C., SILVA, S.H.G., GUILHERME, L.R.G. AND CURI, N., Portable X-ray fluorescence (pXRF) spectrometry applied to the prediction of chemical attributes in Inceptisols under different land uses. **Ciência e Agrotecnologia**, 42(5), pp.501-512. 2018.
- VISCARRA ROSSEL R.A., ADAMCHUK V.I., SUDDUTH K.A., MCKENZIE N.J., LOBSEY C. Proximal Soil Sensing: An Effective Approach for Soil Measurements in Space and Time. **Advances in Agronomy**, v. 113, p. 243–291, 2011.
- 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.

## Diferentes métodos de sensoriamento proximal do dossel de videiras promovem divergências no mapeamento de índices de vegetação

Larissa Godarelli Farinassi<sup>2</sup>; Henrique Oldoni<sup>3</sup>; Luis Henrique Bassoi<sup>4</sup>; Bruno Ricardo Silva Costa<sup>1</sup>

<sup>1</sup>Eng<sup>o</sup> Agrônomo, Doutor em Agronomia (Irrigação e Drenagem) - FCA, UNESP, Botucatu - SP. larissa\_godarelli@hotmail.com / ; <sup>2</sup>Eng<sup>a</sup> Agrônoma, Doutoranda em Agronomia (Irrigação e Drenagem) - Depto. de Engenharia Rural e Socioeconomia, FCA, UNESP, Botucatu - SP; <sup>3</sup>Eng<sup>o</sup> Agrícola, Doutor em Agronomia (Irrigação e Drenagem) - FCA, UNESP, Botucatu - SP; <sup>4</sup>Eng<sup>o</sup> Agrônomo, Pesquisador - Embrapa, Embrapa Instrumentação, São Carlos - SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** A estimativa de índices de vegetação (IV) viabiliza o monitoramento da variabilidade espacial do vigor vegetativo em vinhedos, porém faz-se necessário questionar se diferentes práticas de sensoriamento podem interferir nos resultados obtidos. Este estudo demonstra a discrepância no mapeamento dos IV NDRE e NDVI estimados a partir de duas metodologias de coleta de dados de reflectância ( $\rho$ ) do dossel de videiras, obtidos via sensoriamento proximal. Medidas georreferenciadas de  $\rho$  correspondentes aos comprimentos de onda ( $\lambda$ ) de 670, 730 e 780 nm foram tomadas conforme duas disposições distintas do sensor ativo ACS-430 em relação a copa das plantas. Após a estimativa dos IV a sua predição espacial foi realizada por análise geoestatística e krigagem ordinária. Os valores interpolados foram normalizados e classificados para delimitação de zonas homogêneas (ZH) do vigor vegetativo no vinhedo avaliado. Determinou-se a variabilidade relativa quanto à estimativa dos IV por cada metodologia a partir do cálculo e da predição espacial do coeficiente de variação (CV). A comparação entre as regionalizações de ambos os IV foi realizada por medidas estatísticas de concordância entre os métodos de coleta de dados. Ambos os procedimentos de medida de  $\rho$  produziram estimativas dos IV com uma reduzida dispersão relativa em torno da média. Entretanto, a disposição espacial das ZH do NDRE e NDVI correspondentes a cada metodologia apresenta discrepâncias, dada a concordância “moderada” e “fraca” entre si, respectivamente.

**PALAVRAS-CHAVE:** Vigor vegetativo; *Vitis vinifera* L.; Viticultura de precisão

### DIFFERENT PROXIMAL SENSING METHODS OF GRAPEVINES CANOPY PROMOTE DIVERGENCES IN VEGETATION INDICES MAPPING

**ABSTRACT:** The vegetation indices (VI) estimation supports the identification of spatial variability regarding vegetative growth within vineyards. However, it is necessary to ask whether different sensing practices can interfere with the results. This study shows the discrepancy in VI mapping through NDRE and NDVI estimated from two data collection methodologies adopted to measure the canopy reflectance ( $\rho$ ) of grapevines via proximal sensing. Georeferenced measurements of  $\rho$  at 670, 730 e 780 nm wavelengths ( $\lambda$ ) were taken through two sensor arrangements. The VI were calculated from these  $\rho$  measurements, and their spatial prediction was performed by geostatistics and ordinary kriging. The interpolated values were standardized and categorized to delineate homogeneous zones (HZ) of vegetative growth within the vineyard. The coefficient of variation was calculated (CV) and interpolated to represent the spatial variability concerning the comparison between the sampling methodologies applied to the estimation of each VI. Inter-rater reliability statistics were accounted to compute the agreement between the ZH of each VI and sampling methods. Both procedures produce VI estimates with low variability in relation to the mean. However, the spatial arrangement of ZH defined by the NDRE and NDVI through each sampling method is divergent due to the “moderate” and “weak” agreement between them, respectively.

**KEYWORDS:** Plant vigor; *Vitis vinifera* L.; Precision viticulture

**INTRODUÇÃO:** Medidas de propriedades ópticas das folhas têm sido utilizadas para fins de identificação e caracterização de coberturas vegetais, uma vez que se correlacionam com parâmetros biofísicos associados à condição vegetativa das plantas (Atherton et al., 2017; Féret et al., 2019; Kattenborn et al., 2019). Neste

sentido, o sensoriamento de cultivos agrícolas torna-se possível graças a identificação da assinatura espectral característica das folhas, em especial da reflectância ( $\rho$ ) de parte da radiação solar incidente sobre estas. Por essa razão, os índices espectrais de vegetação (IV) são calculados a partir da relação entre a  $\rho$  correspondente a determinados comprimentos de onda ( $\lambda$ ) (especialmente nas bandas do vermelho visível e infravermelho próximo), de forma a ressaltar a distinção das propriedades referentes à vegetação em oposição àquelas pertinentes a outros alvos. Particularmente no que se refere a cultivares de videiras (*Vitis vinifera* L.), a associação entre IV e características do dossel das plantas foi reportada por Drissi et al. (2009), Caruso et al. (2017) e Junges et al. (2019). Adicionalmente, os IV podem ser utilizados para fins de detecção da variabilidade espacial do desenvolvimento vegetativo das videiras, como demonstrado por Costa et al., 2019, Ferrer et al., 2020 e Darra et al., 2021. Nesta perspectiva, o monitoramento intensivo dos IV no âmbito da agricultura de precisão (AP) aplicada a viticultura é justificado, em razão da necessidade de avaliação contínua de atributos de interesse agrônomo, dentre eles o vigor vegetativo que, de forma análoga à produtividade, constitui-se de um indicativo do potencial produtivo dos vinhedos. Assim, a partir da predição da variabilidade espacial desse atributo, em associação com a avaliação de demais variáveis regionalizadas, têm-se a identificação de zonas homogêneas (ZH) e a delimitação de zonas de manejo (ZM), respectivamente, que podem orientar a implementação de atividades sítio-específico na produção de videiras. Neste contexto, a regionalização do vigor vegetativo em vinhedos pode ser adotada para fins de colheita seletiva (Oldoni et al., 2021), uma vez que essa característica se correlaciona com atributos de produção e composição de bagas. Assim, em razão da utilidade do mapeamento do vigor vegetativo por meio da estimativa de IV, o sensoriamento proximal pode ser utilizado para o monitoramento de vinhedos de pequena extensão pois, nessas condições, essa técnica apresenta vantagens em comparação com o sensoriamento remoto, dada a sua elevada precisão e resolução espectral (Gholizadeh and Kopařková, 2019). Contudo, devido as diversas possibilidades de utilização de sensores proximais, em especial no que se refere ao seu posicionamento em relação ao dossel das videiras, e do grande número de IV disponíveis, a estimativa do vigor vegetativo pode apresentar diferentes padrões de distribuição e variabilidade espacial em um mesmo vinhedo (Costa et al., 2019). Logo, o presente estudo teve como objetivo avaliar se existe discrepâncias quanto à sobreposição de ZH correspondentes a dois diferentes IV (NDRE e NDVI), estimados por meio sensoriamento proximal do dossel de videiras, adotando-se dois procedimentos distintos para coleta de dados de  $\rho$ .

**MATERIAIS E MÉTODOS:** O monitoramento da  $\rho$  do dossel de videiras cv. Syrah foi realizado em um vinhedo comercial de 1,08 ha, situado a 726 m de altitude, nas coordenadas 21°17'24,63"S e 47°50'46,86"O. As videiras foram cultivadas no espaçamento de 2,80 x 1,00 m entre fileiras e plantas, respectivamente, conduzidas em sistema de espaldeira vertical, irrigadas por gotejamento, com poda de formação do tipo cordão Royat bilateral, e submetidas a sistema de dupla poda anual. As medidas de  $\rho$  do dossel foram obtidas por sensoriamento proximal, em uma única ocasião, utilizando-se o sistema portátil *Crop Circle* integrado com o sensor ativo ACS-430 (*Holland Scientific*, Lincoln, NE, EUA), além do *datalogger* GeoSCOUT GLS-400 (*Holland Scientific*, Lincoln, NE, EUA), para armazenamento de dados. Os dados foram georrefenciadas no momento de sua coleta, utilizando-se o receptor GNSS (*Global Navigation Satellite System*) HiPer GGD (TOPCON, Pleasanton, CA, EUA). O sensor utilizado forneceu valores simultâneos de  $\rho$  equivalentes a 670 ( $\rho_R$ , vermelho), 730 ( $\rho_{RE}$ , vermelho limítrofe) e 780 nm ( $\rho_{NIR}$ , infravermelho próximo). Durante a coleta de dados, o equipamento foi programado para aquisição de 10 medidas por segundo e foi deslocado por caminhamento, ao longo de todas as fileiras de plantas do vinhedo.

Duas metodologias de coleta de dados foram adotadas, posicionado o ACS-430 em duas disposições distintas em relação ao dossel das videiras, assumindo-se dois diferentes ângulos de observação em relação ao zênite ( $\theta_v$ ). A metodologia M1 resultou do posicionamento do sensor no topo do dossel das plantas, distanciado a 0,30 m deste, a qual proporcionou um ângulo  $\theta_v$  correspondente à 0° (*nadir*) e um sentido paralelo às fileiras de plantio quanto a projeção do feixe de luz emitido pelo equipamento. Por sua vez, na metodologia M2, o sensor foi posicionado na lateral do dossel a uma distância de 0,80 m, o que resultou em ângulo  $\theta_v$  de 90° (*off-nadir*) e proporcionou um posicionamento perpendicular do feixe luminoso em relação ao dossel das videiras. A partir da razão entre os dados de  $\rho$  em determinados  $\lambda$ , foram calculados dois IV: o NDVI (*normalized difference vegetation index*) e o NDRE (*normalized difference red edge*), conforme as Equações 1 e 2, nesta ordem.

$$NDVI = (\rho_{NIR} - \rho_R) / (\rho_{NIR} + \rho_R) \quad (1)$$



$$NDRE = (\rho NIR - \rho RE) / (\rho NIR + \rho RE) \quad (2)$$

A análise dos dados de  $\rho$  e dos IV consistiu, inicialmente, em uma etapa de pré-processamento, durante a qual foram calculadas medidas numéricas descritivas representativas da tendência central (média) e variabilidade dos dados (desvio padrão e coeficiente de variação). Essa análise orientou a remoção das observações discrepantes, segundo o protocolo descrito por Córdoba et al. (2016). Assim, os valores localizados fora do intervalo entre a média  $\pm 3$  vezes o desvio padrão ( $x \pm 3s$ ), denominados *outliers*, foram removidos. Em seguida, excluiu-se os valores considerados significativamente diferentes daqueles localizados em uma determinada vizinhança definida pela distância euclidiana, denominados *inliers*, identificados conforme o índice local de Moran, calculado para estimativa de autocorrelação espacial (Anselin, 1995). Uma amostra de 100 observações foi selecionada aleatoriamente para fins de cálculo de estatísticas descritivas (média, desvio padrão e coeficiente de variação) do dados de  $\rho$  e dos IV correspondentes à cada metodologia de coleta de dados.

A caracterização espacial baseada na variação e distribuição dos dois IV estimados (NDVI e NDRE), foi realizada por análise geoestatística, utilizando o *software* Vesper versão 1.6 (Minasny et al., 2005). A análise geoestatística foi realizada em duas etapas. Primeiramente, semivariogramas teóricos foram ajustados aos empíricos, predefinindo-se o modelo exponencial para este fim, conforme a Equação 3. Foi utilizado o modo de ajuste local disponibilizado no *software* mencionado, uma vez que a quantidade de observações de  $\rho$  e dos IV ultrapassou 5.000 pontos.

$$\gamma(h) = C0 + C1[1 - \exp(-3 h/a)], \text{ para: } 0 < h < d \quad (3)$$

onde: C0: efeito pepita; C1: patamar; a: alcance; h: distância e d: máxima distância na qual o semivariograma é definido.

A segunda etapa da análise geoestatística consistiu na predição espacial dos IV por meio de krigagem ordinária, utilizando-se a técnica de variogramas delimitados por uma janela móvel (Haas, 1990). Adotou-se o método de krigagem em blocos, com dimensões espaciais de 5 x 5 m e definiu-se os contornos dos vinhedos como limites para geração da grade regular para interpolação, a partir de uma resolução espacial de 0,50 m. Os resultados interpolados dos IV, organizados em formato matricial, constituíram mapas temáticos que foram importados em SIG (Sistema de Informações Geográficas) para pós-processamento dos dados, utilizando-se o *software* QGIS versão 3.10.0 (*QGIS Development Team*, 2019) para este fim. Estes valores interpolados foram submetidos a normalização pela média, o que resultou no cálculo de escores padrões conforme a Equação 4.

$$z_{ij} = (x_{ij} - x_{?j}) / s_j \quad (4)$$

onde:  $z_{ij}$  e  $x_{ij}$ : escore padrão e valor correspondente ao  $i$ -ésimo ponto, respectivamente, do IV estimado conforme a  $j$ -ésima metodologia;  $x_{?j}$ : valor médio do IV pertinente a  $j$ -ésima metodologia;  $s_j$ : desvio padrão do IV referente a  $j$ -ésima metodologia.

As ZH dos IV foram delimitadas com base na classificação dos valores normalizados em duas categorias definidas de acordo com os valores negativos ( $z_i < 0$ ) e positivos ( $z_i > 0$ ) do escore padrão. Desta forma, valores inferiores e superiores à média de cada IV representaram categorias de plantas de menor e maior vigor vegetativo, respectivamente.

A variabilidade relativa dos IV ao longo da área foi inferida por meio do cálculo do coeficiente de variação (CV) referente à comparação entre a predição espacial de ambos os IV estimados segundo os dados de  $\rho$  obtidos por cada metodologia de coleta. Neste sentido, procedeu-se de forma idêntica àquela descrita por Suszek et al. (2011), que descreveram um procedimento para o cálculo do CV a partir de dados normalizados dos escores padronizados. Os valores da predição espacial do CV foram posteriormente classificados em três níveis para fins de delimitação de classes de variabilidade comuns a ambos os IV. A definição dos limites entre classes do CV foi realizada conforme o método de otimização de Jenks, também denominado de quebras naturais, o qual minimizou as diferenças intrínsecas às classes e maximizou as diferenças entre as mesmas.

Por fim, foi avaliada a concordância entre os valores classificados dos IV estimados a partir de cada metodologia, que foram consideradas os avaliadores a serem contrapostos. Deste modo, a partir da elaboração de matrizes de contingência, calculou-se o coeficiente kappa ( $k$ ) (Cohen, 1960) e o índice de Bangdiwala (B)

(Bangdiwala, 1985), que serviram de medidas estatísticas para avaliação da confiabilidade interavaliadores. A magnitude da concordância determinada de acordo com o índice  $k$  foi classificada segundo McHugh (2012), conforme as seguintes designações e intervalos de valores: ausente ( $0 < k \leq 0,20$ ); mínima ( $0,21 \leq k \leq 0,39$ ); fraca ( $0,40 \leq k \leq 0,59$ ); moderada ( $0,60 \leq k \leq 0,79$ ); forte ( $0,80 \leq k \leq 0,90$ ); quase perfeita ( $0,90 < k$ ). A confiabilidade interavaliadores descrita pelo índice  $B$ , o qual apresenta uma amplitude de 0 (ausência de concordância) a 1 (concordância perfeita), foi representada em gráficos propostos por Bangdiwala e Shankar (2013).

**RESULTADOS E DISCUSSÃO:** Na Figura 1 estão representadas as medidas descritivas quanto à  $\rho$  correspondente aos três  $\lambda$  mensurados pelo sensor ativo ASC 430, bem como aos IV estimados a partir desses. Conforme a amostra de 100 observações retiradas dos conjuntos de dados coletados em campo, a  $\rho$  medida a partir da metodologia M1 e M2, respectivamente, apresentou valores médios e desvios padrões iguais a  $3,01 \pm 0,70$  e  $3,40 \pm 0,51$  ( $\rho_R$ );  $19,63 \pm 0,49$  e  $19,52 \pm 0,39$  ( $\rho_{RE}$ ); e  $37,07 \pm 2,41$  e  $37,67 \pm 1,73$  ( $\rho_{NIR}$ ). O padrão de  $\rho_R$  observado pode ser explicado pela elevada absorção da luz no espectro do vermelho visível ( $\approx 660$  nm), característica dos pigmentos fotossintetizantes (clorofilas) (Taiz et al., 2014). Por sua vez, a elevada  $\rho_{NIR}$ , relacionada a interação da luz com as propriedades estruturais do mesófilo foliar (Huete, 2004), decorre do espalhamento múltiplo da radiação incidente, o qual é diretamente proporcional a quantidade de folhas (Kumar et al., 2001). Assumindo-se a mesma sequência de métodos mencionados anteriormente (M1 e M2), a dispersão relativa dos dados em torno da média (CV) da  $\rho$  foi equivalente à 23,26 e 15,00% ( $\rho_R$ ); 2,50 e 2,00% ( $\rho_{RE}$ ); e 6,50 e 4,59% ( $\rho_{NIR}$ ), nesta ordem. Logo, as medidas de  $\rho$  obtidas pelo método M2 apresentaram uma menor variabilidade em comparação àquelas obtidas pelo método M1. A  $\rho_R$  apresentou uma maior dispersão relativa quando comparada àquela correspondente aos demais  $\lambda$ , em especial quanto às medidas obtidas por meio da metodologia M1. Contudo, independentemente do método de coleta de dados, valores reduzidos de  $\rho_R$  e elevados de  $\rho_{NIR}$ , associados a uma baixa variabilidade dos mesmos, revelaram uma condição de vigor vegetativo elevado e uniforme na ocasião da medida de  $\rho$  das videiras.

O NDVI estimado a partir das metodologias M1 e M2, respectivamente, apresentou valores médios equivalentes à  $0,85 \pm 0,03$  e  $0,84 \pm 0,03$ , o que resultou em CV igual a 3,53 e 3,57%, nesta ordem. Por sua vez, os valores médios correspondentes ao NDRE foram iguais a  $0,31 \pm 0,03$  (M1) e  $0,32 \pm 0,03$  (M2), enquanto o CV foi equivalente à 9,68 (M1) e 9,38% (M2). Deste modo, as medidas de  $\rho$  tomadas pelo método M2 proporcionaram estimativas menos dispersas dos IV em estudo. Ambos os métodos de coleta de dados de  $\rho$  resultaram em uma dispersão relativa igualmente reduzida quanto à estimativa do NDVI quando comparada àquela associada ao NDRE. Além disso, este último IV apresentou uma maior variabilidade quando estimado a partir de dados de  $\rho$  coletados pelo método M1. Independente do método de coleta de dados adotado, os valores médios elevados associados a uma reduzida variabilidade do NDVI corroboraram a afirmação sobre o vigor acentuado das videiras observado no momento da coleta de dados, pois indicaram a saturação do índice mencionado. A saturação do NDVI é comumente observada em condições de monitoramento de coberturas vegetais vigorosas, e pode ser atribuída ao desbalanço entre o decréscimo da  $\rho_R$  e o incremento da  $\rho_{NIR}$  como resposta a um elevado índice da área foliar (IAF) (Tesfaye e Awoke, 2020). Além disso, as videiras cv. Syrah apresentam caracteristicamente um maior vigor vegetativo (Robinson et al., 2012).

Na Figura 2 estão representados os mapas de ZH correspondentes aos IV estimados por ambas as metodologias de coleta de dados de  $\rho$  e a predição espacial do CV associado a cada índice. Após a classificação dos valores interpolados normalizados, o NDRE estimado pelos os métodos M1 e o M2 delimitou uma maior porção da área total ocupada por plantas de alto vigor ( $z_i > 0$ ), que foi equivalente à 52,87 (0,57 ha) e 52,37% (0,56 ha), respectivamente. O mesmo ocorreu para o NDVI apenas ao se considerar o método M1, o que resultou em 55,45% (0,60 ha) da área total ocupada por valores acima da média. Portanto, a estimativa do NDVI realizada a com base em dados de  $\rho$  coletados a partir da metodologia M2 foi menos sensível para a detecção de valores acima da média no que diz respeito ao índice em questão.

A variabilidade relativa do vigor vegetativo produzida pelas estimativas dos IV por ambos os métodos de coleta de dados foi baixa, uma vez que a amplitude de variação entre valores mínimos e máximos foi igual a 8,69%. Desta forma, as categorias do CV correspondentes à variabilidade baixa, intermediária e alta, nesta ordem, assumiram os seguintes intervalos de valores: 0,00 a 1,25% (CV 01), 1,25 a 3,11% (CV 02) e 3,11 a 8,69% (CV 03). Apesar da reduzida dispersão relativa, a proporção da área do vinhedo classificada em cada categoria e os padrões espaciais do CV foram variáveis ao longo da extensão da área, conforme os diferentes

IV e métodos de coleta de dados. Contudo, o NDRE indicou que uma menor porção da área foi caracterizada com uma variabilidade alta (CV 03) em comparação ao NDVI. Por essa razão, a dispersão em torno de valores médios foi menor ao se estimar o índice NDRE, em detrimento do NDVI, no que se refere a inferência sobre a distribuição espacial do vigor vegetativo do vinhedo.

Na Figura 3 são apresentadas as medidas estatísticas e os gráficos de concordância interavaliadores utilizados na comparação entre os mapas categóricos dos IV. As ZH delimitadas a partir da estimativa do NDRE obtidas conforme as duas metodologias de coleta de dados de  $\rho$  apresentaram a melhor concordância espacial entre si. Entretanto, segundo a interpretação do coeficiente k, essa concordância foi considerada “moderada” ( $0,60 \leq k \leq 0,79$ ). Por sua vez, a conformidade entre a distribuição espacial de ZH correspondentes aos métodos de coleta de dados utilizados para estimativa do NDVI foi classificada como “mínima” ( $0,21 \leq k \leq 0,39$ ). Este resultado indicou que o posicionamento do sensor ativo ACS-430 em relação ao dossel das videiras promoveu discrepâncias quanto à delimitação de ZH a partir da classificação da predição espacial do vigor vegetativo conforme os IV adotados. Ressalta-se que, a comparação entre os padrões de ZH delimitadas para o NDRE e NDVI estimados a partir da metodologia M1 (Figura 3C) apresentou a maior concordância ( $k = 0,67$ ) dentre todas as paralelas estabelecidas entre os IV e avaliadores em questão. Logo, medidas de  $\rho$  obtidas por sensoriamento proximal a partir do método M1 (topo do dossel) resultaram em padrões de distribuição espacial de ZH semelhantes entre si, assumindo-se ambos os IV.

Conforme a interpretação do índice B, a comparação entre o NDRE estimado com base nas diferentes metodologias de coleta de dados (Figura 3A), revelou uma concordância moderada ( $B = 0,68$ ), porém associada a um viés reduzido. Logo, a delimitação de ZH referentes ao NDRE foi menos influenciada pelos métodos de coleta de dados de  $\rho$  utilizados para a sua estimativa. De modo contrário, o NDVI apresentou a menor concordância ( $B = 0,43$ ) e o maior viés associado a comparação entre as ZH delimitadas conforme as diferentes metodologias adotadas (Figura 3B). Contudo, observou-se um viés reduzido quanto a concordância entre as ZH delimitadas para os diferentes IV estimados a partir dos dados obtidos pelo método M1 (Figura 3C). O mesmo ocorreu na comparação entre as ZH correspondentes ao NDRE e NDVI, delimitadas segundo os dados originados dos métodos M2 e M1, nesta ordem (Figura 3E). Por sua vez, o viés referente à concordância entre as ZH foi mais acentuado e os resultados de k e B apresentaram valores reduzidos no que se referiu a comparação entre os IV e métodos distintos (Figura 3D) e entre as regionalizações do NDRE e NDVI feitas a partir da adoção do método M2 (Figura 3F).

FIGURA 1. Valores médios e respectivos desvios padrão referentes à reflectância do dossel de videiras a 670 ( $\rho_R$ , vermelho), 730 ( $\rho_{RE}$ , vermelho limítrofe) e 780 nm ( $\rho_{NIR}$ , infravermelho próximo) e aos índices de vegetação (IV) NDRE e NDVI obtidos pela adoção de duas metodologias de coleta de dados de  $\rho$  do dossel de videiras. **Mean and standard deviation of the grapevines canopy reflectance at 670 ( $\rho_R$ , red), 730 ( $\rho_{RE}$ , red edge) and 780 nm ( $\rho_{NIR}$ , near infrared) and the NDRE and NDVI vegetation indices according to two sampling methods of grapevines canopy reflectance.**




FIGURA 2. Mapas temáticos representativos da categorização de valores interpolados normalizados correspondentes ao NDVI e NDRE e do coeficiente de variação (CV), obtidos pela adoção de duas metodologias de coleta de dados de  $\rho$  do dossel de videiras. **Thematic maps of the categorized standardized interpolated values of NDVI and NDRE and the relative standard deviation (CV) according to two sampling methods of grapevines canopy reflectance.**

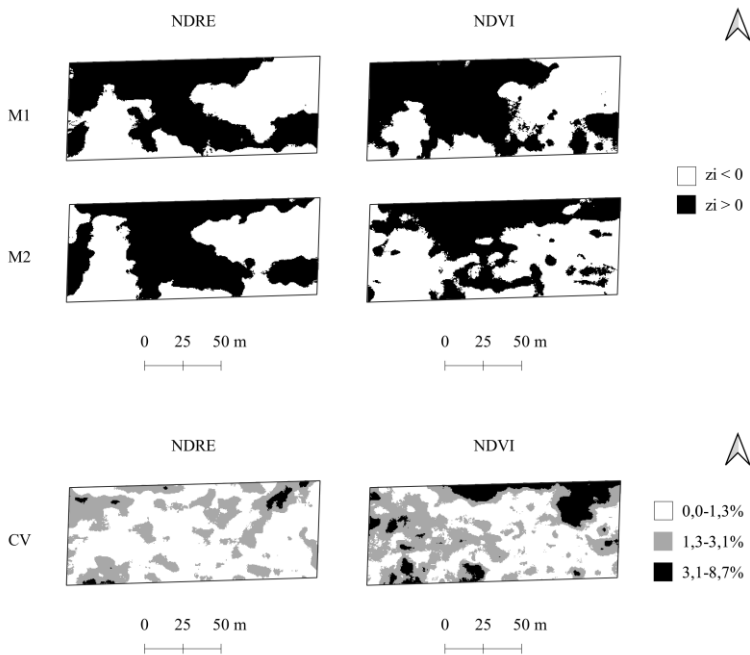



FIGURA 3. Gráficos de concordância referentes à comparação entre as zonas homogêneas dos índices NDRE e NDVI, estimados com base em medidas de reflectância do dossel de videiras obtidas pela adoção de duas metodologias de coleta de dados. **Agreement charts for comparison between categorized homogeneous zones of NDRE and NDVI estimated according to two sampling methods of grapevines canopy reflectance.**



**CONCLUSÃO:** Diferentes métodos de coleta de dados de  $\rho$  do dossel via sensoriamento proximal proporcionam padrões de distribuição de ZH espacialmente distintos para representação do vigor vegetativo de videiras vigorosas conduzidas em espaldeira, conforme os IV NDRE e NDVI. Apesar disso, o NDRE demonstra uma maior concordância quanto à sobreposição de ZH do vigor vegetativo, delimitadas pela medida de  $\rho$  em diferentes disposições do sensor proximal ACS-430 em relação à copa das videiras. Contudo, medidas de  $\rho$  realizadas a partir do topo do dossel das plantas resultam em maior semelhança no mapeamento e delimitação de ZH do NDRE e NDVI em vinhedos.

**AGRADECIMENTOS:**

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão de bolsas de estudo. À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), pelo apoio financeiro. À Rede de Agricultura de Precisão da Embrapa, pelo suporte técnico. À Vinícola Terras Altas, pela concessão da área experimental.

## REFERÊNCIAS

- ANSELIN, L. Local indicators of spatial association – LISA. **Geographical Analysis**, v.27, p.93-115, 1995.
- ATHERTON J.; OLASCOAGA, B; ALONSO, L.; PORCAR-CASTELL, A. Spatial Variation of Leaf Optical Properties in a Boreal Forest Is Influenced by Species and Light Environment. **Frontiers in Plant Science**, v.8, 2017.
- BANGDIWALA, S.I. A Graphical Test for Observer Agreement. **International Statistical Institute**, p.307-308, 1985.
- BANGDIWALA, S.I., SHANKAR, V. The agreement chart. **Medical Research Methodology**, v.13, n.97, 2013.
- CARUSO, G.; TOZZINI, L.; RALLO, G.; PRIMICERIO, J.; MORIONDO, M.; PALAI, G.; GUCCI, R. Estimating biophysical and geometrical parameters of grapevine canopies ('Sangiovese') by an unmanned aerial vehicle (UAV) and VIS-NIR cameras. **Vitis**, v.56, n.2, p.63-70, 2017.
- COHEN, J. A Coefficient of Agreement for Nominal Scales. **Educational and Psychological Measurement**, v.20, n.1, p.37-46, 1960.
- CÓRDOBA, M.A., BRUNO, C.I., COSTA, J.L., PERALTA, N.R., BALZARINI, M.G. Protocol for multivariate homogeneous zone delineation in precision agriculture. **Biosystem Engineering**, v.143, p.95-107, 2016.
- COSTA, B.R.S.; OLDONI, H.; ROCHA JUNIOR, R.; BASSOI, L.H. Delimitation of homogeneous zones in vineyards using geostatistics and multivariate analysis of different vegetation indices. **Engenharia Agrícola**, v.39, p.13–22, 2019.
- DARRA, N.; PSOMIADIS, E.; KASIMATI, A.; ANASTASIOU, A.; ANASTASIOU, E.; FOUNTAS, S. Remote and proximal sensing-derived spectral indices and biophysical variables for spatial variation determination in vineyards. **Agronomy**, v.11, n.4:741, 2021.
- DRISSI, R.; GOUTOULY, J.P.; FORGET, D.; GAUDILLERE, J.P. Nondestructive measurement of grapevine leaf area by ground Normalized Difference Vegetation Index. **Agronomy Journal**, v.101, p.226–231, 2009.
- FÉRET, J.-B.; LE MAIRE, G.; JAY, S.; BERVEILLER, D.; BENDOULA, R.; HMIMINA, G.; CHERAIETF, A.; OLIVEIRA, J.C.; PONZONI, F.J.; SOLANKI, T.; DE BOISSIEUA, F.; CHAVEK, J.; NOUVELLON, Y.; LEFÈVRE-FONOLLOSA, PORCAR-CASTELLJ, A.; PROISYM, C.; SOUDANIF, K.; GASTELLU-ETCHEGORRY, J.-P.; LEFÈVRE-FONOLLOSA, M.-J. Estimating leaf mass per area and equivalent water thickness based on leaf optical properties: Potential and limitations of physical modeling and machine learning. **Remote Sensing of Environment**, v.231, 2019.
- FERRER, M.; ECHEVERRÍA, G.; PEREYRA, G.; GONZALEZ-NEVES, G.; PAN, D.; MIRÁS-AVALOS, 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.

- GHOLIZADEH, A.; KOPAŇKOVÁ, V. Detecting vegetation stress as a soil contamination proxy: a review of optical proximal and remote sensing techniques. **International Journal of Environmental Science and Technology**, v.16, p.2511–2524, 2019.
- HAAS, T.C. Kriging and automated variogram modeling within a moving window. **Atmospheric Environment. Part A. General Topics**, v.24, n.7, p.1759-1769, 1990.
- HUETE, A.R. Remote sensing for environmental monitoring. In ARTIOLA, J.F.; PEPPER, I.L.; BRUSSEAL, M. (Eds.), **Environmental Monitoring and Characterization**, Elsevier Science & Technology Books, 2004, p.183-206.
- JUNGES, A.H.; FONTANA, D.C.; LAMPUGNANI, C.S. Relationship between the normalized difference vegetation index and leaf area in vineyards. **Bragantia**, v.78, n.2, p.297-305, 2019.
- KATTENBORN, T.; FASSNACHT, F.E.; SCHMIDTLEIN, S. Differentiating plant functional types using reflectance: which traits make the difference?. **Remote Sensing in Ecology and Conservation**, v.5, n.1, p.5-19, 2019.
- KUMAR, L.; SCHMIDT, K.; DURY, S.; SKIDMORE, A. Imaging spectrometry and vegetation science. In F. D. van der Meer & S. M. de Jong (Eds.), **Imaging spectrometry**. Dordrecht: Kluwer Academic Publishers, 2001, p.111–155.
- McHUGH M. Interrater Reliability: The Kappa Statistic. **Biochemia Medica**, v.2, n.3, p.276-282, 2012.
- 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, n.4, 2021.
- QGIS DEVELOPMENT TEAM. **QGIS Geographic Information System**. Open Source Geospatial Foundation Project. 2019. Disponível em: <http://qgis.osgeo.org/>.
- ROBINSON, J.; HARDING, J.; VOUILLAMOZ, J. **Wine Grapes: complete guide to 1,368 vine varieties, including their origins and flavours**. London: Ecco Press, 2012, 394p.
- SUSZEK, G.; SOUZA, E.G.; URIBE-OPAZO, M.A.; NOBREGA, L.H.P. Determination of management zones from normalized and standardized equivalent productivity maps in the soybean culture. **Engenharia Agrícola**, v.31, n.5, p.895-905, 2011.
- TAIZ L.; ZEIGER, E.; MØLLER, I. M.; MURPHY, A. Photosynthesis: the light reactions. In. SINAUER, A. D. (Ed.), **Plant Physiology and Development**. Sunderland, Massachusetts: Sinauer Associates, Inc., 2014, p.171-202.

# Variabilidade espacial da condutividade elétrica aparente ao longo do perfil do solo de vinhedos comerciais

Bruno Ricardo Silva Costa<sup>1</sup>; Larissa Godarelli Farinassi<sup>2</sup>; Ladislau Marcelino Rabello<sup>3</sup>; Carlos Manoel Pedro Vaz<sup>4</sup>; Luís Henrique Basso<sup>5</sup>

<sup>1</sup>Engº Agrônomo, Doutor em Agronomia (Irrigação e Drenagem) - FCA, UNESP, Botucatu - SP. bruno.ricardo.silva@hotmail.com / (11) 9 8574-3364; <sup>2</sup>Engª Agrônoma, Doutoranda em Agronomia (Irrigação e Drenagem) - Depto. de Engenharia Rural e Socioeconomia, FCA, UNESP, Botucatu - SP; <sup>3</sup>Engº Elétrico, Pesquisador - Embrapa Instrumentação, São Carlos - SP; <sup>4</sup>Físico, Pesquisador - Embrapa Instrumentação, São Carlos - SP; <sup>5</sup>Engº Agrônomo, Pesquisador - Embrapa Instrumentação, São Carlos - SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** A caracterização da variabilidade espacial da condutividade elétrica aparente do solo (CEa) de vinhedos comerciais a partir do sensoriamento proximal dessa propriedade em diferentes intervalos de profundidade do perfil é apresentada nesse estudo. Medidas de CEa, representativas dos intervalos de profundidade de 0-0,20, 0-0,40, 0-0,50 e 0-1,00 m, foram feitas a partir da superfície do solo em dois vinhedos comerciais utilizando um medidor portátil desenvolvido pela Embrapa Instrumentação e o sensor EM38-MK2. A dependência espacial da CEa foi avaliada por meio de análise geoestatística, seguida da predição espacial por krigagem ordinária. Os valores estimados da CEa foram normalizados e classificados para delimitação de zonas homogêneas (ZH) e elaboração de mapas categóricos deste atributo. A magnitude da associação espacial entre as regionalizações da CEa em intervalos de profundidades distintos foi realizada pelo cálculo de indicadores de concordância implementados para comparação de mapas temáticos. A CEa apresenta variabilidade espacial ao longo do perfil do solo, porém o padrão de distribuição de ZH desse atributo nos vinhedos é variável conforme o intervalo de profundidade e a área avaliada. A maior concordância entre os mapas categóricos de CEa correspondentes aos intervalos de profundidades superficiais do solo (0-0,20 e 0-0,40 m) indicam que essas camadas podem apresentar semelhança quanto aos seus atributos físico-químicos.

**PALAVRAS-CHAVE:** Sensoriamento proximal; Comparação de mapas; Vitivinicultura

## SPATIAL VARIABILITY OF APPARENT ELECTRICAL CONDUCTIVITY WITHIN THE SOIL PROFILE OF COMMERCIAL VINEYARDS

**ABSTRACT:** This study characterizes the spatial variability of soil apparent electrical conductivity (ECa) within commercial vineyards through proximal sensing of this property at different depths. ECa measurements comprising four depths ranges, 0-0.20, 0-0.40, 0-0.50, and 0-1.00 m, were taken in two commercial vineyards using a portable meter developed by Embrapa Instrumentation and the EM38-MK2 sensor. The spatial dependence of ECa was evaluated through geostatistical analysis, followed by the spatial prediction by ordinary kriging. The estimated ECa values were normalized and categorized to define homogeneous zones (HZ) and produce categorical maps of this attribute. The magnitude of the spatial association between the ECa regionalizations at different depths ranges was performed by calculating concordance indicators to compare thematic maps. ECa presents spatial variability throughout the soil profile, but the HZ distribution across the vineyards varies according to the soil depth and field. The major agreement between categorical maps of ECa at the surface depth ranges (0-0.20 e 0-0.40 m) indicates that these soil layers may present equivalent physicochemical attributes.

**KEYWORDS:** Proximal sensing; Map comparison; Winegrowing

**INTRODUÇÃO:** Dentre as propriedades do solo passíveis de mapeamento, a condutividade elétrica aparente (CEa) assume destaque, uma vez que a sua medida se coaduna com demais atributos físico-químicos de importância para a agricultura. Neste sentido, a identificação da dependência espacial da CEa torna-se uma ferramenta essencial para a implementação de práticas de agricultura de precisão (AP), no intuito de elevar a eficiência produtiva e rentabilidade das culturas agrícolas, conforme a adoção de práticas de manejo sítio

específico, quando necessário. A aplicação dessa abordagem torna-se especialmente relevante para agregar valor em culturas de alto retorno econômico, a exemplo do cultivo de variedades de videiras voltadas para a produção de vinho, ou vitivinicultura. Porém, uma vez que essas culturas são perenes o seu sistema radicular explora maiores profundidades do solo, o que justifica a descrição das propriedades dos seus demais horizontes. Desta forma, este estudo teve como objetivo caracterizar a variabilidade espacial da CEa ao longo do perfil do solo de vinhedos comerciais e investigar se existem diferenças quanto à concordância entre os mapas categóricos desse atributo em intervalos de profundidade distintos.

**MATERIAIS E MÉTODOS:** O monitoramento da CEa do solo foi realizado em dois vinhedos comerciais (A e B) cultivados com as videiras cv. Syrah (*Vitis vinifera* L.). Os vinhedos localizaram-se nas seguintes coordenadas: 21°17'24,63"S e 47°50'46,86"O, 726 m de altitude (vinhedo A); 21°42'40,59"S e 46°55'58,37"O, 825 m de altitude (vinhedo B). As videiras foram cultivadas no espaçamento de 2,80 x 1,0 m (vinhedo A) e 2,50 x 1,0 m (vinhedo B) entre fileiras e plantas, respectivamente, e conduzidas em sistema de espaldeira vertical, com poda de formação do tipo cordão Royat bilateral. As medidas de CEa do solo corresponderam a quatro intervalos de profundidades (0-0,20, 0-0,40, 0-0,50 e 0-1,00 m) e foram tomadas por meio de sensoriamento proximal, em uma única ocasião, durante o ciclo de formação da cultura (outubro de 2019), de acordo com o manejo da dupla poda anual. Foi utilizado o medidor portátil descrito por Rabello (2009) para a realização de medidas de CEa a 0-0,20 e 0-0,40 m em 321 e 275 pontos distribuídos ao longo dos vinhedos A e B, respectivamente. Essas medidas foram georreferenciadas no momento de sua coleta, utilizando-se o receptor GNSS (*Global Navigation Satellite System*) HiPer GGD (TOPCON, Pleasanton, CA, EUA). Por sua vez, foi utilizado o sensor EM38-MK2 (Geonics Limited, Mississauga, Ontario, Canadá) para a medida da CEa a 0-0,50 e 0-1,00 m. Esses dados também foram georreferenciados no momento da sua medida, porém foram coletados de forma contínua, deslocando o sensor ao longo das fileiras de plantas. No total, 19.155 e 17.587 pontos amostrais foram coletados por essa técnica nos vinhedos A e B, nesta ordem. Os dados de CEa coletados por ambos os equipamentos foram submetidos a uma etapa de pré-processamento, para o cálculo de medidas numéricas descritivas de tendência central (média,  $\bar{x}$ ) e variabilidade (desvio padrão, sd), seguida pela remoção das observações discrepantes (*outliers e inliers*), conforme o protocolo descrito por Córdoba et al. (2016). Após o pré-processamento dos dados, a variabilidade espacial da CEa foi caracterizada por meio de análise geoestatística, utilizando-se o *software* Vesper versão 1.6 (Minasny et al., 2005). Foram ajustados semivariogramas teóricos isotrópicos (ajuste global) para os dados de CEa referentes aos intervalos de profundidades de 0-0,20 e 0-0,40 m, escolhendo modelos específicos, cujo melhor ajuste foi determinado conforme o menor valor da raiz quadrada do erro quadrático médio (RMSE). No caso das camadas de 0-0,50 e 0-1,00 m, devido a densidade amostral (> 5.000 pontos), foram ajustados semivariogramas locais (ajuste local) para os dados de CEa adotando-se o modelo exponencial para este fim, definido conforme a Equação 1.

$$\gamma(h) = C_0 + C_1[1 - \exp(-3 h/a)], \text{ para: } 0 < h < d \quad (1)$$

onde:  $\gamma(h)$ : valor da semivariância para o modelo ajustado,  $C_0$ : efeito pepita;  $C_1$ : patamar;  $a$ : alcance;  $h$ : distância e  $d$ : máxima distância na qual o semivariograma é definido.

Após o ajuste dos semivariogramas, a predição espacial da CEa foi feita por krigagem ordinária, a partir da técnica de variogramas delimitados por uma janela móvel (Haas, 1990). Foi adotado o método de krigagem em blocos, com dimensões espaciais de 5 x 5 m, considerando as grades regulares para interpolação com resolução espacial de 0,50 m, definidas a partir dos limites de cada vinhedo. Por fim, no pós-processamento dos dados, os resultados interpolados dos IV foram importados no *software* SIG (Sistema de Informações Geográficas) QGIS versão 3.10.0 (*QGIS Development Team*, 2019). Assim, os dados interpolados foram transformados segundo a normalização pela média, o que resultou no cálculo de escores padrões conforme a Equação 2.

$$z_{ij} = (x_{ij} - x_{mj}) / s_j \quad (2)$$

onde:  $z_{ij}$  e  $x_{ij}$ : escore padrão e valor correspondente a  $i$ -ésima observação, respectivamente, da CEa estimada para a  $j$ -ésima profundidade do solo;  $x_{mj}$ : valor médio da CEa pertinente a  $j$ -ésima profundidade de solo;  $s_j$ : desvio padrão da CEa referente a  $j$ -ésima profundidade do solo.



Na sequência, foram produzidos mapas categóricos (temáticos) a partir da delimitação de zonas homogêneas (ZH) da CEa do solo em cada profundidade por meio da classificação dos valores normalizados em duas categorias definidas de acordo com os valores negativos (ZH1,  $z_i < 0$ ) e positivos ( $z_i > 0$ ) do escore padrão. Após a classificação dos dados, as ZH distribuídas ao longo dos vinhedos foram representadas sobre grades hexagonais. Por fim, para avaliar a concordância entre as regionalizações da CEa ao longo do perfil do solo, o nível de associação espacial entre as ZH definidas em cada mapa referente aos diferentes intervalos de profundidade foi determinada por meio da medida teórica-informativa denominada *V-measure* (Nowosad e Stepinski 2018). Esta medida mensura o grau de conformidade entre mapas categóricos e varia entre 0 (ausência de concordância) e 1 (concordância perfeita). O cálculo da medida mencionada foi realizado utilizando-se a linguagem de programação R versão 3.6.2 e as funções implementadas na biblioteca “sabre” (*Spatial Association Between REgionalizations*, versão 0.4.0).

**RESULTADOS E DISCUSSÃO:** Na Figura 1 são apresentados os mapas categóricos elaborados a partir das medidas de CEa ao longo do perfil do solo em ambos os vinhedos avaliados. A análise geoestatística permitiu a identificação da variabilidade espacial da CEa e a delimitação de ZH distintas a partir das predições deste atributo. Esta caracterização pode ser útil para a identificação da inconstância dos vinhedos quanto às suas propriedades físico-químicas do solo (Rodríguez-Pérez et al., 2011), bem como em relação às condições fisiológicas das videiras, a exemplo do seu conteúdo de água (Yu et al, 2021). Nesse sentido, a discretização do vinhedo a partir da variabilidade espacial do solo e das plantas pode ser adotada como um *proxy* para guiar a implementação de práticas de AP na vitivinicultura, conforme demonstrado por Bramley et al. (2011). A Tabela 1 resume os resultados da medida de associação espacial entre os mapas categóricos correspondentes a cada intervalo de profundidade avaliado em cada área. Dentre todas as comparações realizadas, foi observado que as camadas superficiais do solo apresentaram maior concordância entre si quanto à distribuição de ZH da CEa nos dois vinhedos. Isso indica que os intervalos de profundidade de 0-0,20 e 0-0,40 m podem ser semelhantes no que se refere aos atributos físico-químicos do solo, especialmente no vinhedo B (*V-measure* = 0,71). Contudo, independente do vinhedo, o nível de concordância entre os mapas categóricos reduziu a medida em que a caracterização da variabilidade espacial da CEa se aprofundou no perfil. Assim, características intrínsecas das camadas de solo de cada área monitorada, em especial daquelas localizadas a 1,0 m, podem estar relacionadas ao nível de discrepância na variabilidade da CEa, uma vez que esse atributo varia espacialmente de forma proporcional a outros atributos do solo (Caroll e Oliver, 2005).

FIGURA 1. Mapas categóricos de valores interpolados normalizados da CEa do solo medida em diferentes intervalos de profundidade. **Thematic maps of the standardized interpolated values of soil ECa at different depth ranges.**

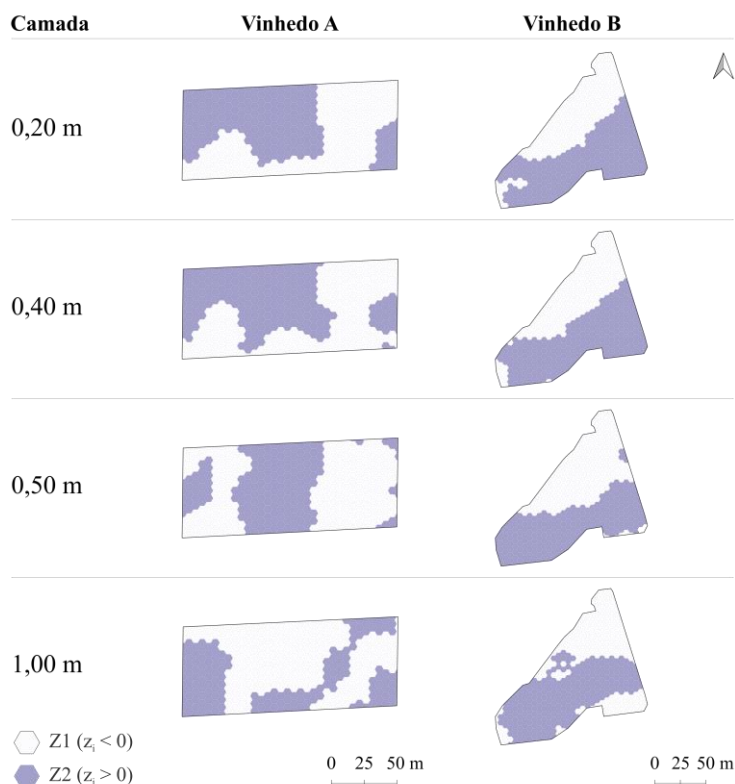


TABELA 1. Indicador de concordância espacial (*V-measure*) entre mapas categóricos da CEa do solo medida em diferentes intervalos de profundidade. **Indicator of spatial agreement (*V-measure*) between categorical maps of soil ECa at different depth ranges.**

Profundidade	<i>V-measure</i>							
	Vinhedo A				Vinhedo B			
	0-0,20 m	0-0,40 m	0-0,50 m	0-1,00 m	0-0,20 m	0-0,40 m	0-0,50 m	0-1,00 m
0-0,20 m	1,00	-	-	-	1,00	-	-	-
0-0,40 m	0,49	1,00	-	-	0,71	1,00	-	-
0-0,50 m	0,17	0,15	1,00	-	0,48	0,45	1,00	-
0-1,00 m	0,02	0,06	0,01	1,00	0,14	0,17	0,15	1,00

**CONCLUSÃO:** A CEa apresenta variabilidade espacial ao longo do perfil do solo de vinhedos comerciais, porém a magnitude da concordância entre os mapas categóricos desse atributo é dependente da profundidade e da área em que foi monitorada. Camadas superficiais do solo (0-0,20 e 0-0,40 m) apresentam uma maior similaridade entre si quanto a variabilidade espacial da CEa, indicando uma possível semelhança no que se refere aos atributos físico-químicos do solo.

#### AGRADECIMENTOS:

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão de bolsas de estudos. À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), pelo apoio financeiro. À Rede

de Agricultura de Precisão da Embrapa, pelo suporte técnico. Às Vinícolas Casa Verrone e Terras Altas, pela concessão das áreas experimentais.

#### REFERÊNCIAS

- BRAMLEY, R., TROUGHT, M. and PRAAT, J.-P. Vineyard variability in Marlborough, New Zealand: characterizing variation in vineyard performance and options for the implementation of Precision Viticulture. **Australian Journal of Grape and Wine Research**, v.17, p.72-78, 2011.
- CARROLL, Z.L.; OLIVER, M.A. Exploring the spatial relations between soil physical properties and apparent electrical conductivity. **Geoderma**, v.128, p.354-374, 2005.
- CÓRDOBA, M.A.; BRUNO, C.I.; COSTA, J.L.; PERALTA, N.R.; BALZARINI, M.G. Protocol for multivariate homogeneous zone delineation in precision agriculture. **Biosystem Engineering**, v.143, p.95-107, 2016.
- HAAS, T.C. Kriging and automated variogram modeling within a moving window. **Atmospheric Environment. Part A. General Topics**, v.24, n.7, p.1759-1769, 1990.
- MINASNY, B.; MCBRATNEY, A.B.; WHELAN, B.M. **Vesper version 1.62**. Sydney: Australian Centre for Precision Agriculture. 2005.
- NOWOSAD, J.; STEPINSKI, T.F.; Spatial association between regionalizations using the information-theoretical V-measure. **International Journal of Geographical Information Science**, p.1-16, 2018.
- RABELLO, L.M. **Condutividade elétrica do solo, tópicos e equipamentos**. São Carlos: Embrapa Instrumentação Agropecuária, 2009. 19 p. (Documentos, 43)
- RODRÍGUEZ-PÉREZ, J.R.; PLANT, R.E.; LAMBERT, J.J.; SMART, D.R. Using apparent soil electrical conductivity (ECa) to characterize vineyard soils of high clay content. **Precision Agriculture**, v.12, p.775-794, 2011.
- YU, R.; ZACCARIA, D.; KISEKKA, I; KURTURAL, K. Soil apparent electrical conductivity and must carbon isotope ratio provide indication of plant water status in wine grape vineyards. **Precision agriculture**, v.22, p.1333-1352, 2021.

# SISTEMA EMBARCADO PARA PREDIÇÃO DE CÁLCIO E MAGNÉSIO EM AMOSTRAS DE SOLO

Thiago Furtado de Oliveira<sup>1</sup>; Domingos Sarvio Magalhães Valente<sup>2</sup>

<sup>1</sup>Eng<sup>o</sup> Agrícola e Ambiental, Doutorando - Departamento de Engenharia Agrícola, , Depto. Engenharia de Agrícola, UFV, Viçosa . thiago.oliveira@ufv.br / (31) 9 9747-6401; <sup>2</sup>Eng Agrícola e Ambiental, Professor - Departamento de Engenharia Agrícola, , Depto. Engenharia de Agrícola, UFV, Viçosa

Apresentado no

**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**

Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Os mapas gerados por interpolação na agricultura de precisão muitas vezes necessitam de um denso grid amostras para representarem com fidelidade a variabilidade espacial dos atributos do solo, o que vezes pode levar os produtores a adotarem um grid amostral que resultará em mapas não confiáveis. Devido a rapidez nas análises e baixo custo por amostra a espectrometria VIR-NIR vem sendo empregada na predição dos atributos dos solos com sucesso. Porém o uso desta tecnologia está limitada a laboratórios de pesquisa, onde é possível utilizar o espectroradiômetro, equipamento de elevado custo utilizado na aquisição dos espectros, em seguida é preciso aplicar os modelos, etapa geralmente realizada por computadores. Portanto o objetivo deste trabalho é desenvolver um sistema embarcado portátil para predição do cálcio e magnésio diretamente de amostras do solo. O sistema embarcado foi desenvolvido utilizando dois sensores espectrais totalizando 246 bandas compreendidas entre 410 nm e 1600 nm. Os espectros utilizados para treinamento dos modelos de *machine learning* foram obtidos de amostras de terra fina seca ao ar e de solo saturado com água destilada. Os espectros foram pré-processados para correção do espalhamento utilizando o método *Standard Normal Variate* (SNV). Para predição dos atributos os modelos utilizados foram o *Support Vector Regression* (SVR), *Partial Least Square Regression* (PLSR), *Random Forest* (RF) e *Multi-Layer Perceptron Regression* (MLPR). Para comparação e seleção do melhor modelo para cada atributo, foram utilizadas as métricas R<sup>2</sup>, RMSE e RPD. O modelo que apresentou melhor capacidade preditiva para o cálcio foi o RF com R<sup>2</sup>, RMSE e RPD de respectivamente de 0,63, 0,37 e 1,64 e para o magnésio o melhor modelo foi o PLSR com valores de R<sup>2</sup>, RMSE e RPD iguais a 0,65, 0,097 e 1.68 respectivamente. De acordo com os resultados, o sistema embarcado se capaz de realizar a predição do cálcio e magnésio diretamente em amostras de solo.

**PALAVRAS-CHAVE:** Calcio e Magnésio; Sistema embarcado; Machine Learning

## EMBEDDED SYSTEM FOR CALCIUM AND MAGNESIUM PREDICTION IN SOIL SAMPLES

**ABSTRACT:** The maps generated by interpolation in precision agriculture often require a dense sample grid to faithfully represent the spatial variability of soil attributes, which can sometimes lead farmers to adopt a sample grid that will result in unreliable maps. Due to the fast analysis and low cost per sample, the VIS-NIR spectrometry has been successfully used in to predict soil attributes. However, this technology is limited to research laboratories, where it is possible to use spectroradiometers, expensive types of equipment used to acquire spectra. Then it is necessary to apply the models, a step usually performed by computers. Therefore, this work aims to develop a portable, embedded system for predicting calcium and magnesium directly from soil samples. The embedded system was developed using two spectral sensors totalizing 246 bands between 410 nm and 1600 nm. The spectra used to train the machine learning models were obtained from samples of sieved air-dried soil and soil saturated with distilled water. The spectra were preprocessed using the *Standard Normal Variate* (SNV) method for scattering correction. For attribute prediction, the models used were *Support Vector Regression* (SVR), *Partial Least Square Regression* (PLSR), *Random Forest* (RF), and *Multi-Layer Perceptron Regression* (MLPR). For comparison and selection of the best model for each attribute, the R<sup>2</sup>, RMSE, and RPD metrics were used. The model that showed the best predictive ability for calcium was RF with R<sup>2</sup>, RMSE, and RPD of respectively 0.63, 0.37, and 1.64. For magnesium, the best model was PLSR with R<sup>2</sup>, RMSE, and RPD values equal to 0.65, 0.097 and 1.68, respectively. According to the results, the embedded system is suitable for predicting calcium and magnesium directly in soil samples.

**KEYWORDS:** Calcium and Magnesium; Embedded System; Machine Learning

**INTRODUÇÃO:** A geoestatística tem sido amplamente adotada para estudar e representar a variabilidade espacial das características do solo. Por meio de processos de interpolação, é possível estimar os valores das variáveis de interesse entre os pontos amostrados (Lauzon et al., 2005). Porém, as propriedades do solo apresentam diferentes distribuições espaciais em diferentes escalas, assim, a confiabilidade da interpolação está intimamente relacionada com a característica estudada e a densidade amostral coletada.

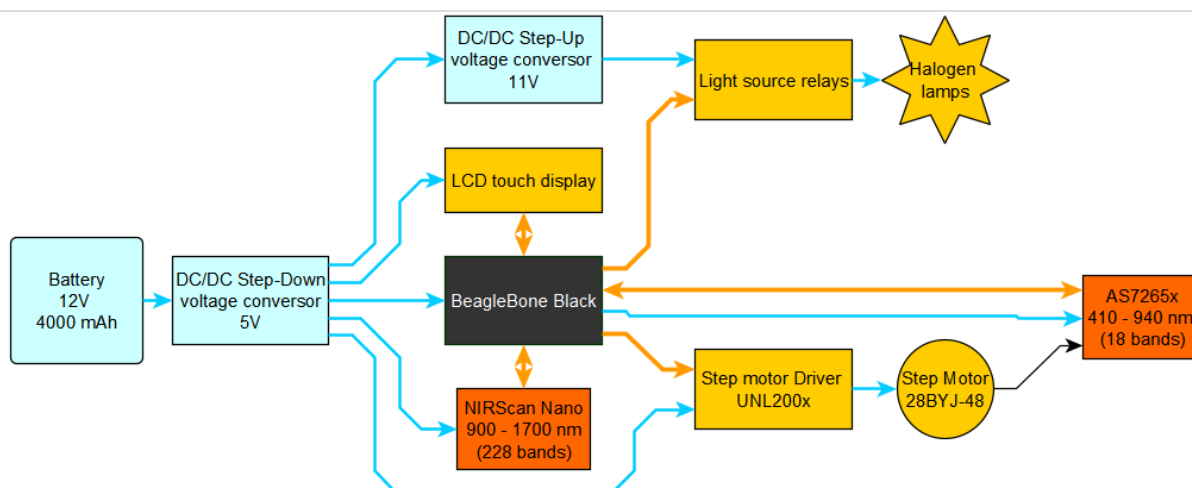
A densidade do grid amostral necessária para representar a variabilidade das características do solo é dependente da característica estudada e da estratégia de amostragem utilizada, e pode ser diferentes entre talhões (Han et al., 1994). Esta conclusão é reforçada pelas diferentes densidades amostrais necessárias para representar a variabilidade espacial apresentadas por diferentes estudos. Mallarino e Wittry (2004) em estudo entre diferentes métodos de amostragem para determinação do fósforo, potássio, pH e matéria orgânica, concluem que a amostragem em grid com cinco amostras por hectare apresentou melhor resultados. Lauzon et al. (2005) estudando a variabilidade do fósforo total, potássio total e pH, em 23 campos diferentes, concluíram ser necessário um grid amostral de 30 m x 30 m ou menor para representar fielmente a variabilidade.

A necessidade de usar elevadas densidades amostrais para caracterização da variabilidade espacial das características do solo resultam em elevado custo com análises laboratoriais, o que tem levado os produtores a adotarem um número de amostras insuficientes para geração de mapas confiáveis. Com o objetivo de reduzir os custos e o tempo de análise, a espectrometria de amostras de solo utilizando os comprimentos de onda do visível e infravermelho próximo (VIS-NIR) tem sido utilizada.

Diversos autores mostraram a capacidade da espectrometria VIS-NIR para a predição de diferentes atributos físico-químicos do solo. Silva et al. (2019) obteve coeficientes de determinação de 0,73 e 0,83 para predição do teor de areia e argila respectivamente. Tziolas et al. (2019) obtiveram valores de  $r^2$  da ordem de 0,72, 0,86, 0,74, 0,84 e 0,78 para carbono orgânico, pH, condutividade elétrica, argila e areia respectivamente. Xu et al. (2018) em estudo de estimativa de matéria orgânica, nitrogênio total, fósforo total e potássio total, obtiveram  $r^2$  de 0,88, 0,86, 0,76 e 0,65 respectivamente.

Embora seja uma técnica que resulta em menor custo com análises, a espectrometria VIS-NIR necessita de sensores (espectrorradiômetro) de alto custo para aquisição dos espectros, que posteriormente precisam ser processados para extração das informações. Com isso o objetivo deste trabalho é o desenvolvimento de um sensor embarcado de baixo custo capaz de realizar a aquisição e processamento dos espectros VIS-NIR em amostras de solo e a aplicação de algoritmos de machine learning.

**MATERIAIS E MÉTODOS:** Os sensores utilizados para aquisição da reflectância foram o AS7265x *Spectral Triad* desenvolvida pela *SparkFun* e o NIRScan Nano desenvolvido pela *Texas Instruments*. Os sensores são controlados por uma BeagleBone Black, responsável pelo controle do sistema de aquisição, processamento dos dados, aplicação dos modelos gerados, exibição da interface gráfica.



(a)



(b)

FIGURA 1. (a) Fluxograma dos componentes do sistema embarcado. Setas azuis são fluxos de energia, em laranja fluxo de informação, e em preto movimento; (b) sistema embarcado AISpec.

Para obtenção dos espectros as amostras de solo foram secas ao ar e peneiradas em peneira 2 mm. Em seguida, foram acondicionadas 2 cm<sup>3</sup> de solo em cubetas de 4,5 ml, para cada amostra foram obtidos quatro espectros. Foram obtidos também espectro das amostras saturadas, para isso foram adicionados 1 ml de água destilada em cada cubeta, e após mistura, foram obtidos dois espectros para cada amostra. A base de dados utilizada no treinamento dos modelos foi composta pela união dos espectros das amostras secas em conjunto com o espectro das amostras saturadas.

Para o treinamento dos modelos foram utilizadas 417 amostras de solo, coletadas em áreas com diferentes sistemas de plantio (plantio direto, plantio convencional e cultivo mínimo) localizada no município de Barbacena/MG. Os espectros obtidos com o sistema embarcado foram pré-processados para correção do espalhamento utilizando o método *Standard Normal Variate* (SNV). Os espectros corrigidos foram utilizados para cálculo de índices espectrais por diferença, índices normalizados e índices por diferença normalizada para todas as combinações de bandas possíveis. Os dados de treinamento e validação foram compostos por 85% e 15% das amostras respectivamente, e em seguida os espectros anômalos foram removidos por meio do algoritmo *Isolation Forest*.

Os modelos utilizados foram o *Support Vector Regression* (SVR), *Partial Least Square Regression* (PLSR), *Random Forest* (RF) e *Multi-Layer Perceptron Regression* (MLPR). A seleção das variáveis foi realizada com algoritmo genético, minimizando a raiz quadrada do erro quadrático médio (RMSE) para cada modelo. Para comparação da capacidade preditiva dos modelos foram utilizadas as métricas RMSE, RPD, R<sup>2</sup>.

**RESULTADOS E DISCUSSÃO:** A Tabela 1 mostra os valores das estatísticas descritivas dos resultados das análises laboratoriais das 417 amostras obtidas pelo método padrão.

TABELA 1. Estatística descritiva dos valores obtidos pela análise laboratorial das 417 amostras utilizadas para treinamento e validação dos modelos.

	Média	Mediana	Desvio padrão	CV (%)	Mínimo	Máximo
pH (H <sub>2</sub> O)	5.56	5.55	0.40	7.28	4.37	6.78
P	20.97	12.88	25.08	119.60	2.05	194.52
K	55.41	47.10	31.18	56.27	12.10	219.40

Ca	1.17	1.03	0.66	56.62	0.11	3.81
Mg	0.29	0.25	0.19	63.89	0.03	1.04
Al	0.26	0.20	0.74	284.67	0.00	14.94
(H + Al)	4.52	4.50	1.03	22.78	2.22	11.81
P-rem	25.29	25.72	3.53	13.94	16.32	33.88
S.B.	1.60	1.45	0.82	51.45	0.25	4.46
t	1.86	1.69	1.01	54.16	0.81	16.66
T	6.12	6.07	0.92	15.12	3.39	12.30
V	26.06	24.44	12.38	47.50	3.67	66.73
m	16.73	12.37	16.17	96.65	0.00	89.64

CV – coeficiente de variação (%); P – fósforo pelo método da resina (mg/dm<sup>3</sup>); K – potássio (mg/dm<sup>3</sup>); Ca – cálcio (cmol/dm<sup>3</sup>); Mg – magnésio (cmol/dm<sup>3</sup>); Al – alumínio (cmol/dm<sup>3</sup>); (H + Al) – acidez potencial (cmol/dm<sup>3</sup>); P-rem – fósforo remanescente (mg/L); SB – soma de bases (cmol/dm<sup>3</sup>); t – ctc efetiva (cmol/dm<sup>3</sup>); T – ctc potencial (cmol/dm<sup>3</sup>); V – índice de saturação por bases (%); m – índice de saturação por alumínio (%).

O modelo com melhor capacidade preditiva para o cálcio foi o RF, com valores de R<sup>2</sup>, RMSE e RPD de 0.63, 0.37 e 1.64 respectivamente. Para predição do magnésio o melhor modelo foi o PLSR, com R<sup>2</sup>, RMSE e RPD iguais a 0.65, 0.097 e 1.68 respectivamente (Tabela 2).

TABELA 2. Métricas obtidas pelos modelos para predição de cálcio e magnésio, em negrito estão destacados os melhores resultados para cálcio e magnésio.

	R <sup>2</sup>		RMSE		RPD	
	Ca	Mg	Ca	Mg	Ca	Mg
SVR	0.55	0.63	0.41	0.099	1.49	1.65
PLSR	0.51	<b>0.65</b>	0.42	<b>0.097</b>	1.43	<b>1.68</b>
RF	<b>0.63</b>	0.64	<b>0.37</b>	0.098	<b>1.64</b>	1.67
MLPR	0.56	0.62	0.40	0.100	1.50	1.63

R<sup>2</sup> – coeficiente de determinação; RMSE – raiz quadrada do erro quadrático médio; RPD – relação de predição/desvio; SVR – *Support vector Regression*; PLSR – *partial least square Regression*; RF – *Random Forest*; MLPR – *multi-layer perceptron Regression*.

O modelo RF para predição do cálcio utilizou como variáveis de entrada 42 índices de diferença normalizada, 43 índices normalizados e 42 índices por diferença, totalizando 127 variáveis. Como mostrado na Figura 2 foram selecionados comprimentos de onda no visível relacionados com óxidos de ferro, como a goethita e a hematita (650 nm, 404 nm e 434 nm) (Nguyen et al. 1991 e Rossel; Behrens 2010). No infravermelho próximo foram selecionados comprimentos de ondas relacionados com e argilominerais como a caulinita (1395 nm e 1415 nm) e compostos orgânicos, como compostos aromáticos (1100 nm), aminas (1000 nm e 1500 nm), ácidos carboxílicos (1449 nm), polissacarídeos (1170 nm) e carboidratos (1050 nm) (Nguyen et al., 1991 e Rossel; Behrens 2010).

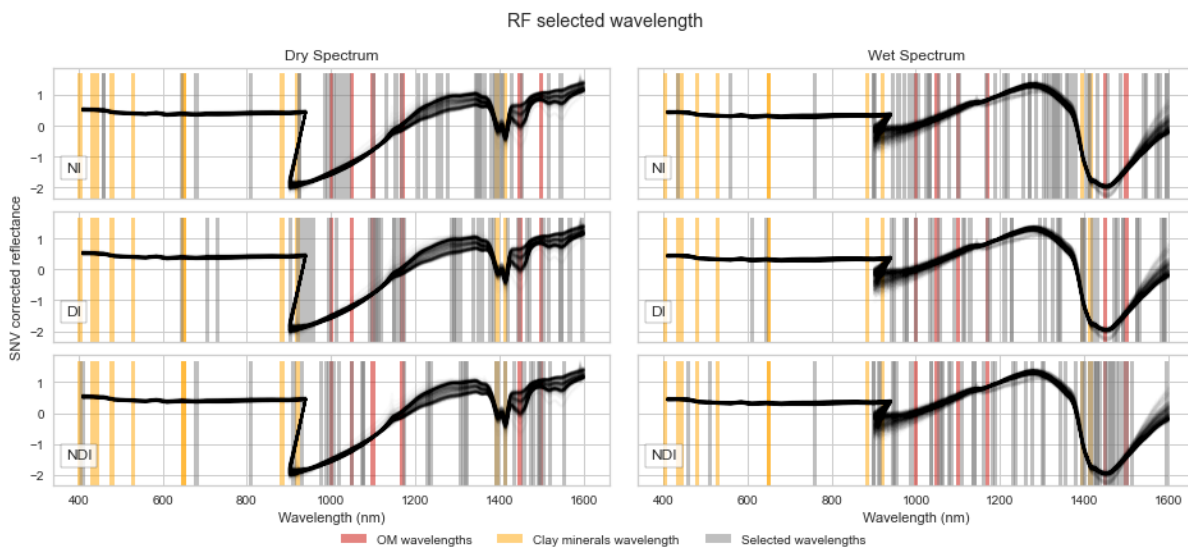


FIGURA 2. Comprimentos de onda utilizados no modelo RF para predição do cálcio. Os espectros das 417 amostras estão plotados em preto. NI, DI e NDI indicam os comprimentos de onda selecionados para cálculo dos índices normalizados, índices por diferença e índice por diferença normalizada respectivamente.

Dentre as features mais importantes para o modelo RF na predição do cálcio (Figura 3), destacam-se no NIR comprimentos de onda em torno de 1100nm, 1500nm que estão relacionados aos compostos orgânicos do solo e comprimentos de onda relacionados às moléculas de água presentes nos óxidos de Fe como em 1400 nm. O comprimento de onda de 560 nm presente entre as features de maior importância, foi destacado por Vohland et al. (2014) entre os comprimentos de onda utilizados para a predição do carbono orgânico nos solos.




FIGURA 3. Features de maior importância no modelo RF para predição do cálcio. O pós escrito 'x' identifica comprimentos de onda do solo seco e o pós-escrito 'y' indica comprimentos de onda do solo saturado.

O modelo PLSR selecionado para predição do magnésio utilizou 12 índices por diferença normalizada, 14 índices normalizados e 17 índices por diferença, totalizando 43 features (Figura 4). Assim como no modelo gerado para o cálcio, destacam-se no NIR os comprimentos de onda relacionados aos compostos orgânicos 1100 nm, 1170 nm e 1500 nm, e os comprimentos de onda 1400 nm e 1455 nm relacionados à absorção pela água e hidroxilas nos óxidos de Fe. Nos comprimentos de onda do visível, foram selecionados comprimentos de onda próximos a 404 nm e 529 nm, que são relacionados aos óxidos de Fe Goethita e Hematita (Nguyen et al. 1991 e Rossel; Behrens 2010).






FIGURA 4. Comprimentos de onda utilizados no modelo PLSR para predição do magnésio. Os espectros das 417 amostras estão plotados em preto. NI, DI e NDI indicam os comprimentos de onda selecionados para cálculo dos índices normalizados, índices por diferença e índice por diferença normalizada respectivamente.

A Figura 5 mostra as features mais importantes para o modelo PLSR de predição do magnésio. No NIR podemos destacar os comprimentos de onda possivelmente relacionados aos compostos orgânicos como 1521 nm, 1497 nm, 1164 nm. No visível, se destaca o comprimento de onda de 485 nm, relacionado à Goethita (Nguyen et al. 1991 e Rossel; Behrens 2010).




FIGURA 5. Features de maior importância no modelo PLSR para predição do magnésio. O pós escrito 'x' identifica comprimentos de onda do solo seco e o pós-escrito 'y' indica comprimentos de onda do solo saturado.

Os índices de maior importância selecionados pelos modelos são compostos de comprimentos de onda proveniente dos dois conjuntos de dados (amostras secas e amostras saturadas), assim fica clara a importância da combinação dos conjuntos de dados para geração dos índices e a performance dos modelos.

Comparados aos argilominerais como a caulinita e os óxidos de ferro e alumínio, os colóides orgânicos apresentam elevados valores de superfície específica e por consequência alta capacidade de troca de cátions Da Costa *et al.* (2020). Assim podemos destacar a importância dos comprimentos de onda relacionados com a matéria orgânica do solo com na quantificação dos cátions em solos com elevado grau de intemperismo como os solos tropicais, onde há predominância de óxidos de ferro e alumínio e argilominerais mais intemperizados como o grupo das caulinitas com baixa superfície específica.

Segundo Chang *et al.* (2001) e Dunn *et al.* (2002) os modelos podem ser classificados quanto a sua capacidade preditiva como excelentes com RPD maior que 2, aceitáveis com RPD entre 1,4 e 2 e modelos não confiáveis com RPD menor que 1,4. Portanto os modelos gerados tanto para cálcio quanto magnésio com RPD de 1,639

e 1,678 respectivamente (Figura 6), podem ser considerados preditores aceitáveis na quantificação destes elementos em amostras de solo.

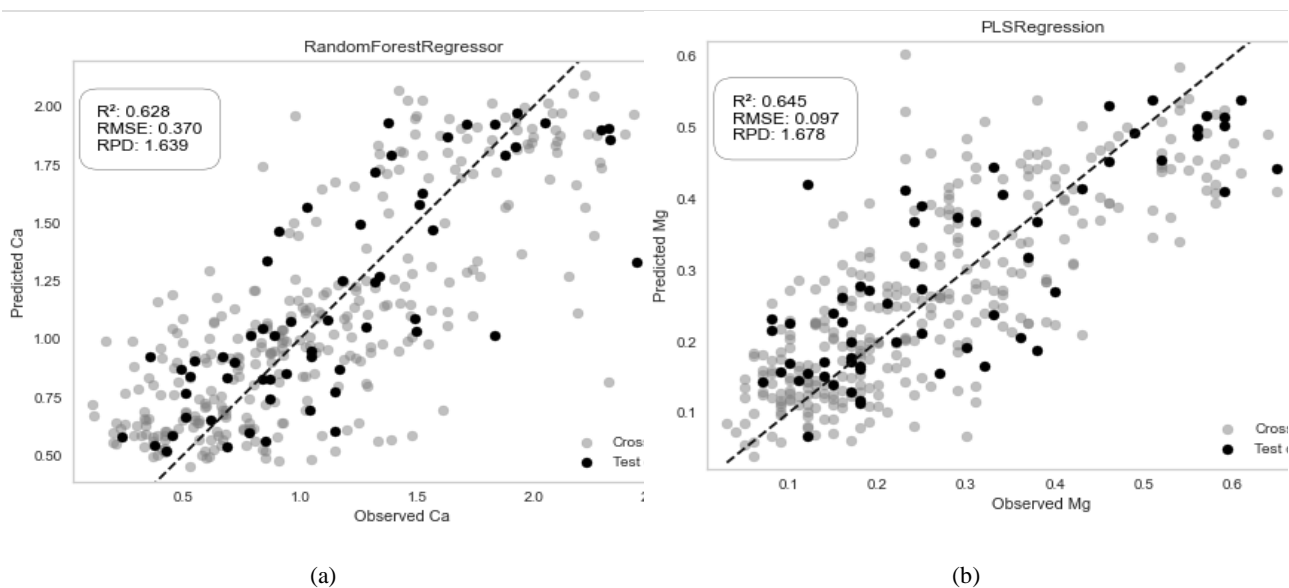


FIGURA 6. Valores observados vs valores preditos dos melhores modelos para cálcio (RF) (a) e magnésio (PLSR) (b). Os valores de  $R^2$ , RMSE e RPD são referentes aos dados de teste.

Apesar de não atingir precisão analítica na predição do cálcio e magnésio, o sistema embarcado apresenta potencial para determinação da variabilidade espacial destes elementos. Uma vez que a análise é realizada de forma rápida e sem custo com reagentes, torna-se viável a utilização de um grid amostral com mais de uma amostra por hectare. O que possibilitaria conhecer a variabilidade espacial do Ca e Mg e guiar a amostragem do solo para realização das análises laboratoriais. A possibilidade de utilizar o sistema embarcado para determinar a variabilidade espacial dos atributos do solo e guiar a amostragem deve ser futuramente avaliada quanto sua capacidade de gerar mapas mais confiáveis e/ou reduzir o número de amostras quando comparado com os métodos padrões de amostragem do solo.

**CONCLUSÃO:** O sistema embarcado apresentou resultados aceitáveis na predição do cálcio e magnésio diretamente em amostras de solo.

Devido ao baixo custo e rapidez das análises o sistema embarcado apresenta grande potencial para determinação da variabilidade espacial do cálcio e magnésio, possibilitando o uso de um grid denso que pode ser utilizado para guiar a amostragem do solo. Estudos futuros precisam analisar a viabilidade desta aplicação.

#### AGRADECIMENTOS:

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela concessão da bolsa de estudos.

#### REFERÊNCIAS

CHANG, C. W.; LAIRD, D. A.; MAUSBACH, M. J.; HURBURGH, J. Near-infrared reflectance spectroscopy - Principal components regression analyses of soil properties. **Soil Science Society of America Journal**, v. 65, n. 2, p. 480–490, 2001.

DA COSTA, A. C. S.; JUNIOR, I. G. DE S.; CANTON, L. C.; GIL, L. G.; FIGUEIREDO, R. Contribution of the chemical and mineralogical properties of sandy-loam tropical soils to the cation exchange capacity. **Revista Brasileira de Ciencia do Solo**, v. 44, p. 1–18, 2020.

- DUNN, B. W.; BEECHER, H. G.; BATTEN, G. D.; CIAVARELLA, S. The potential of near-infrared reflectance spectroscopy for soil analysis - A case study from the Riverine Plain of south-eastern Australia. **Australian Journal of Experimental Agriculture**, v. 42, n. 5, p. 607–614, 2002.
- HAN, S.; HUMMEL, J. W.; GOERING, C. E.; CAHN, M. D. Cell size selection for site-specific crop management. **Transactions of the ASAE**, v. 37, n. 1, p. 19–26, 1994. American Society of Agricultural and Biological Engineers.
- LAUZON, J. D.; O’HALLORAN, I. P.; FALLOW, D. J.; VON BERTOLDI, A. P.; ASPINALL, D. Spatial variability of soil test phosphorus, potassium, and pH of Ontario soils. **Agronomy Journal**, v. 97, n. 2, p. 524–532, 2005.
- MALLARINO, A. P.; WITTRY, D. J. Efficacy of grid and zone soil sampling approaches for site-specific assessment of phosphorus, potassium, pH, and organic matter. **Precision Agriculture**, v. 5, n. 2, p. 131–144, 2004.
- NGUYEN, T. T.; JANIK, L. J.; RAUPACH, M. Diffuse Reflectance Infrared Fourier Transform ( DRIFT ) Spectroscopy in Soil Studies. , , n. 1982, p. 49–67, 1991.
- RIBEIRO, S. G.; TEIXEIRA, A. D. S.; DE OLIVEIRA, M. R. R.; et al. Soil organic carbon content prediction using soil-reflected spectra: A comparison of two regression methods. **Remote Sensing**, v. 13, n. 23, 2021.
- ROSSEL, R. A. V.; BEHRENS, T. Using data mining to model and interpret soil diffuse reflectance spectra. **Geoderma**, v. 158, n. 1–2, p. 46–54, 2010. Elsevier B.V.
- SILVA, E. B.; GIASSON, É.; DOTTO, A. C.; et al. A Regional Legacy Soil Dataset for Prediction of Sand and Clay Content with Vis-Nir-Swir, in Southern Brazil. **Revista Brasileira de Ciência do Solo**, v. 43, n. August, 2019.
- TZIOLAS, N.; TSAKIRIDIS, N.; BEN-DOR, E.; THEOCHARIS, J.; ZALIDIS, G. A memory-based learning approach utilizing combined spectral sources and geographical proximity for improved VIS-NIR-SWIR soil properties estimation. **Geoderma**, v. 340, n. December 2018, p. 11–24, 2019. Elsevier.
- VOHLAND, M.; LUDWIG, M.; THIELE-BRUHN, S.; LUDWIG, B. Determination of soil properties with visible to near- and mid-infrared spectroscopy: Effects of spectral variable selection. **Geoderma**, v. 223–225, n. 1, p. 88–96, 2014. Elsevier.
- XU, S.; ZHAO, Y.; WANG, M.; SHI, X. Comparison of multivariate methods for estimating selected soil properties from intact soil cores of paddy fields by Vis–NIR spectroscopy. **Geoderma**, v. 310, n. September 2017, p. 29–43, 2018.

# APLICAÇÃO DO ÍNDICE DE VEGETAÇÃO PARA CORRELAÇÃO DO DESENVOLVIMENTO REPRODUTIVO DO AÇAIZEIRO

JAMILE DO NASCIMENTO SANTOS<sup>1</sup>; IZADORA DE CASSIA MESQUITA DA CUNHA<sup>2</sup>; ODAILSON RODRIGUES DO NASCIMENTO<sup>3</sup>; YARA KARINE DE LIMA SILVA<sup>4</sup>; FABIO JÚNIOR DE OLIVEIRA<sup>5</sup>

<sup>1</sup>Eng<sup>a</sup> Agrônoma, Mestranda - Departamento de Engenharia e Ciências Exatas, UNESP, Jaboticabal - SP. Jamile.n.santos@unesp.br / ; <sup>2</sup>Eng<sup>a</sup> Agrônoma, Mestranda - Biologia Celular e molecular, ESALQ, USP, Piracicaba - SP; <sup>3</sup>Eng<sup>o</sup> Agrônomo, Graduado - Campus Capitão Poço, UFRA, Capitão Poço - PA ; <sup>4</sup>Eng<sup>a</sup> Agrônoma, Doutoranda - Departamento de Engenharia e Ciências Exatas, UNESP, Jaboticabal - SP; <sup>5</sup>Eng<sup>o</sup> Agrônomo, Professor - Campus Capitão Poço, UFRA, Capitão Poço - PA

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** A cadeia produtiva do açaízeiro (*Euterpe oleraceae* Mart.) vem se expandindo e trazendo consigo várias iniciativas e inovações. Tecnologias do Sensoriamento Remoto permitem a obtenção de imagens multiespectrais da vegetação e têm mostrado potencial em seu uso para monitoramento e estimativa de diversos parâmetros agronômicos. Objetivamos correlacionar os índices de vegetação em função dos desenvolvimento reprodutivo do açaízeiro . O trabalho foi realizado em um cultivo comercial de açaízeiro, no município de Capitão Poço – PA. O delimitamento experimental foi em Blocos ao Acaso, com 8 parcelas contendo 6 touceiras cada. Foram analisadas as variáveis: Número de Espata Floral, Número de Inflorescência, Número de Cacho Verde, Número de Cacho Preto e Número de Folhas. Para a aquisição de ortofotos, a fim de avaliar o NDVI (Índice de Vegetação por Diferença Normalizada) e SAVI (Índice de Vegetação por Diferença Normalizada Ajustada ao Solo) do açaízeiro, foi usado RPA (Aeronaves Remotamente Pilotadas) com câmera multiespectral Mapir Survey 3. Observou-se que o NDVI e SAVI possuem correlação para a variável Número de Cachos Pretos. Isso indica que é possível explicar as variáveis fenológicas reprodutivas do açaízeiro possibilitando ao produtor informações prévias do cultivo sendo ferramenta eficaz de gestão agrícola.

**PALAVRAS-CHAVE:** Sensoriamento Remoto; RPAS; *Euterpe oleracea* Mart

## ANALYSIS OF THE REPRODUCTIVE PHENOLOGICAL DEVELOPMENT OF THE AÇAIZEIRO BY MEANS OF AIRBORNE REMOTE SENSING

**ABSTRACT:** The productive chain of the açaí nut tree (*Euterpe oleraceae* Mart.) has been expanding and bringing with it several initiatives and innovations. Remote sensing technologies allow obtaining multispectral images of vegetation and have shown potential in their use for monitoring and estimation of various agronomic parameters. The objective of this study was to analyze the reproductive phenological development of the açaí palm using aerial remote sensing. The work was performed in a commercial açaízeiro plantation in Capitão Poço, PA. The experimental design was in Randomized Blocks, with 8 plots containing 6 clumps each. The following variables were analyzed: number of flower spathe, number of inflorescence, number of green cluster, number of black cluster and number of leaves. For the acquisition of orthophotos, in order to evaluate the NDVI (Normalized Difference Vegetation Index) and SAVI (Soil Adjusted Normalized Difference Vegetation Index) of the açaízeiro, RPA (Remotely Piloted Aircraft) with a Mapir Survey 3 multispectral camera was used. It was observed that NDVI and SAVI have correlation for the variable Number of Black Clusters. This indicates that it is possible to explain the phenological reproductive variables of the açaí tree, providing the producer with information prior to cultivation as an effective tool for agricultural management.

**KEYWORDS:** Vegetation Index ; RPAS; *Euterpe oleracea* Mart

**INTRODUÇÃO:** O açaízeiro (*Euterpe oleracea* Mart.) é uma palmeira natural de várzeas da Amazônia. A polpa do seu fruto se popularizou na produção industrial ou artesanal de sorvetes, geléias e licores (NASCIMENTO, 2008). Com a crescente demanda de consumo, o açaí passou a ter um cultivo mais intensivo e com investimento em pesquisas voltadas para sua produção em terra firme (SILVA, 2017).

Estudar a fenologia de uma espécie constitui ferramenta eficaz de manejo que possibilita identificar, o momento fisiológico ao qual se encontram associadas às necessidades do vegetal, além da estimativa de produtividade (CÂMARA, 2006), que no geral é realizada via conhecimento de agricultores ou dos procedimentos de amostragem em áreas representativas (MOUTINHO, 2018).

Dentre as tecnologias que permitem fazer análises sobre a cobertura vegetal destaca-se o uso de aeronaves remotamente pilotadas (Remotely Piloted Aircraft System - RPAS), popularmente conhecidos como drone, que permitem a obtenção de imagens aéreas de grandes áreas com baixo custo, com maior frequência e com alta resolução (VILLAR; ROSAS; PINTO, 2020).

O uso de imagens multiespectrais coletadas por sensores embarcados em RPAS possibilita a geração de índices de vegetação (IV), que são operações algébricas com base na reflectância em bandas espectrais específicas, permitindo extrair diferentes variáveis de comportamento, padrão, uniformidade e a situação fisiológica do alvo, o qual permitem obter informações de campo a um custo menor em relação a outros métodos (CRUZ; SOUZA; JESUS, 2011; JENSEN, 2009).

A partir do pressuposto e de poucos estudos acerca da aplicação do sensoriamento remoto para a cultura do açaizeiro, objetivamos analisar o desenvolvimento fenológico reprodutivo do açaizeiro por meio de Sensoriamento Remoto Aéreo

## **MATERIAIS E MÉTODOS:**

O trabalho foi realizado em um plantio comercial de açaizeiro (*Euterpe oleracea* Mart.), no município de Capitão Poço, PA, em um talhão de cultivo irrigado de açaizeiro com aproximadamente 9.800 touceiras, espaçadas em 5x5 m, com 7 anos de idade no período de avaliação. Foram distribuídas 8 parcelas com 6 touceiras, sendo cada touceira constituída de 2 estípes. Todas receberam os mesmos tratamentos culturais. As avaliações foram realizadas de março a maio de 2021, nas datas 26/03 (Avaliação 1) 15/04 (Avaliação 2), 30/04 (Avaliação 3), 15/05 (Avaliação 4) e 30/05 (Avaliação 5), registrando-se, de forma visual, o número das variáveis fenológicas: espata floral, inflorescência, cachos verdes (imaturos), cachos pretos (maduros); e vegetativa: número de folhas.

Após cada avaliação fenológica, foram realizados os voos com a utilização de RPA modelo Mavic 2 PRO da DJI no qual foi acoplada câmera Mapir modelo Survey3W RGN que captura no Red (vermelho) + Green(verde) + NIR (Infravermelho próximo) para geração dos índices de vegetação.

O plano de voo foi realizado no aplicativo Litchi da empresa *VC Technology Ltda*, com altura de voo de 120 m, com sobreposição lateral e longitudinal de 70 e 60%, respectivamente, a uma velocidade de 11 m s<sup>-1</sup>.

As imagens foram processadas no Software *Agisoft Metashape 1.7.2*, para confecção do ortofotomosaicos, os quais foram exportadas para o Software *QGIS* versão 3.16. para extração dos IV (Tabela 1) dos alvos. Em seguida foi criado um arquivo shapefile composto de 48 polígonos para cada avaliação, abrangendo as copas das touceiras analisadas de cada parcela(Figura 1) , que foram utilizados para realização da estatística descritiva.

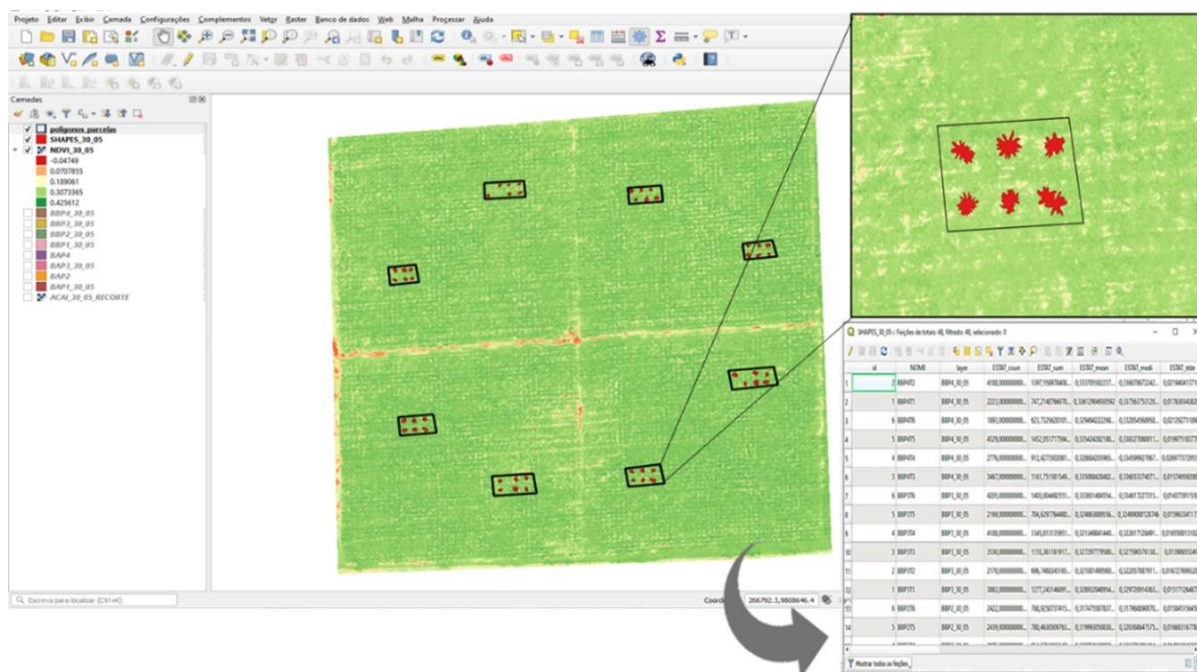


Figura 1- Distribuição das parcelas avaliadas em campo e polígonos utilizados para extração dos valores dos índices estudados. **Distribution of plots evaluated in the field and polygons used for extraction of the index values studied.**

TABELA 1. Índices de vegetação (IV) utilizados. **Vegetation Indices (IV) used.**

IV	Equação	Referência
NDVI	$(NIR - Red) / (NIR + Red)$	ROUSE <i>et al.</i> (1974)
SAVI	$(1+L) (NIR - Red) / (L + NIR + Red)$	HUETE (1988)

L: fator de correção para a interferência do solo (0,50)

As médias dos IVs e os dados das variáveis fenológicas (N° de Espata Floral, N° de Inflorescência, N° de Cachos Verdes, N° de Cachos Pretos e N° de folhas) foram submetidos ao teste de normalidade Shapiro Wilk (p-valor < 0,05) e homocedacidade pelo teste de Bartlett (p-valor < 0,05) e ao teste de Independência dos resíduos Durbin-Watson (p-valor < 0,05). Após foram submetidos a ANOVA e posteriormente ao teste de medias SNK (p-valor < 0,05). As fontes de variação da ANOVA foram as datas de avaliação.

Posteriormente os dados foram submetidos a análises de correlação entre as variáveis. Todos os procedimentos estatísticos foram por meio do *Software R* (R Core Team, 2016).

## RESULTADOS E DISCUSSÃO:

Realizou-se análise descritiva para os índices de vegetação para verificar o comportamento dos dados (Tabela 2). Foi calculada a contagem de pixels para cada avaliação que apresentaram valores de 3375, 3258, 4030, 3193 e 3518 pixels, dos quais foram extraídos os valores dos índices para as cinco avaliações.

A média dos valores dos índices foram de: 0,3322 0,3289, 0,3275, 0,3347 e 3,289 para o NDVI e 0, 4984, 0, 4934, 0,4912, 0,5020 e 0,4933 para o SAVI, para as cinco avaliações, onde encontram-se com variância e desvio padrão baixos (Tabela 2), evidenciando que os valores estão uniformemente distribuídos e com margem de erro próximas aos valores da média. Os valores máximo e mínimo de NDVI e SAVI, demonstram que os dados apresentam valores com pequena variação, o que significa que para vetorização das touceiras foram selecionadas apenas pixels que representam a copa da planta.

TABELA 2. Estatística descritiva referente aos valores de NDVI e SAVI extraídos das touceiras analisadas para as avaliações 1, 2, 3, 4 e 5. **Descriptive statistics for NDVI and SAVI values extracted from the analyzed clumps for evaluations 1, 2, 3, 4, and 5.**

	Avaliação 1	Avaliação 2	Avaliação 3	Avaliação 4	Avaliação 5
NDVI					
Contagem	3375,3333	3257,5833	4029,8958	3193,4167	3517,9792
Média	0,3322	0,3289	0,3275	0,3347	0,3289
Variância	0,0004	0,0004	0,0005	0,0002	0,0003
Desvio Padrão	0,0185	0,0197	0,0225	0,013	0,0177
Máximo	0,3805	0,3785	0,378	0,376	0,3795
Mínimo	0,2253	0,2291	0,2073	0,2814	0,2359
p-Valor (95.0%)	0,0023	0,0021	0,0022	0,0014	0,0018
SAVI					
Contagem	3375,3333	3257,5833	4029,8958	3193,4167	3517,9792
Média	0,4984	0,4934	0,4912	0,502	0,4933
Variância	0,0008	0,0009	0,0012	0,0004	0,0007
Desvio Padrão	0,0277	0,0295	0,0338	0,0195	0,0265
Máximo	0,5707	0,5677	0,5669	0,5639	0,5692
Mínimo	0,3379	0,3436	0,3109	0,4221	0,3539
p-Valor (95.0%)	0,0035	0,0032	0,0033	0,0022	0,0027

Ao longo das avaliações a diferença visual de cores é imperceptível NDVI E SAVI (Figura 2), porém ao analisar os resultados numéricos (Tabela 2), os índices apresentam diferenças entre os valores máximos e mínimos devido a adição da constante “L” no índice SAVI, que modifica a escala de valores para o índice, proporcionando um intervalo mais amplo que pode ser explorado para a arquitetura foliar do açazeiro que é pinatisecta, característica pelos recortes que chegam até a nervura principal, de forma que esses espaços podem expor o solo que é um fator considerado pelo SAVI.



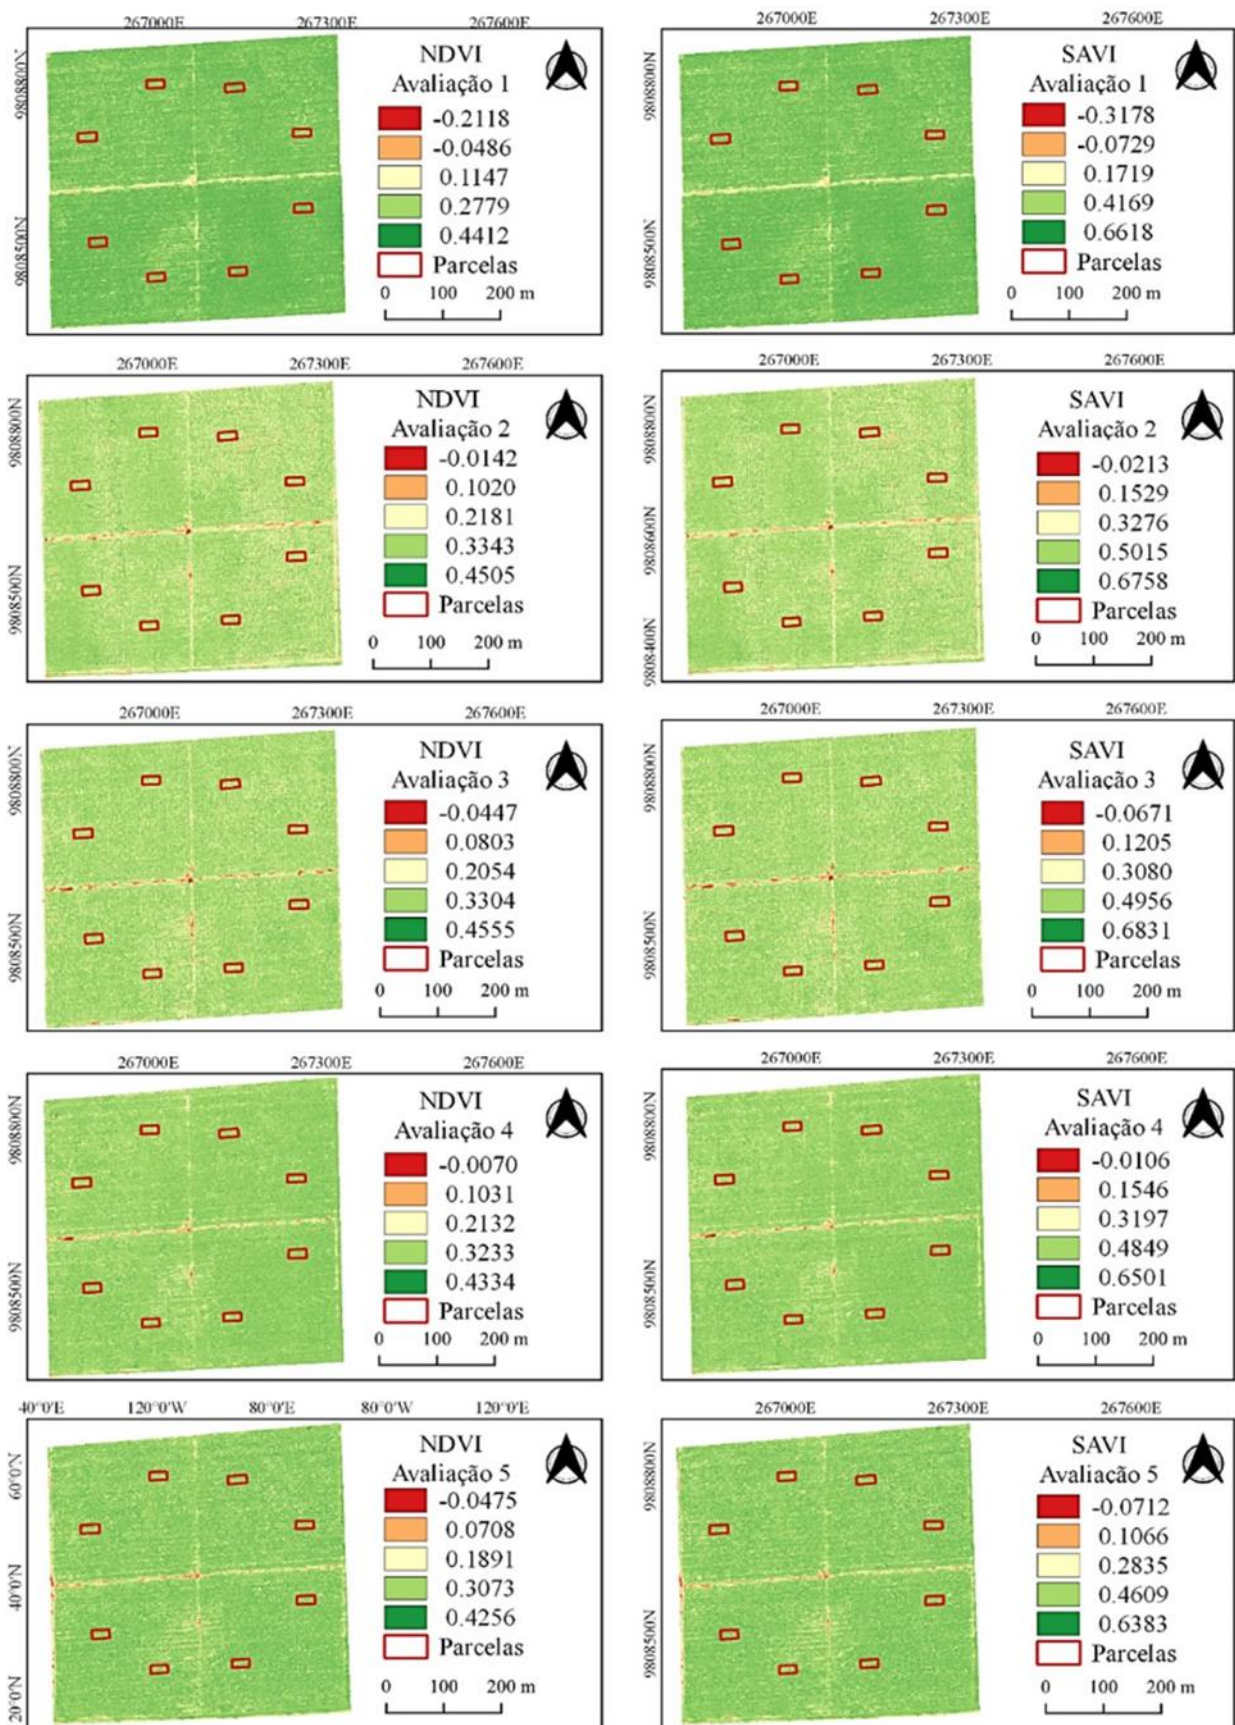


FIGURA 2. Comparativo entre ortofotomosaicos de NDVI e SAVI para as avaliações 1, 2, 3, 4 e 5. **Comparison of NDVI and SAVI orthophotomosaics for assessments 1, 2, 3, 4, and 5.**

Na avaliação 1 o tom de verde dos IV's tende à médias mais altas entre os talhões (Figura 2), porém as médias encontradas para os valores de pixel das touceiras tenderam a um verde mais claro com médias de 0,33 para NDVI e 0,49 para SAVI (Tabela 2). Isso pode ter ocorrido provavelmente devido a diferença de sincronicidade



nos estágios de frutificação do açazeiro, a qual pode-se inferir que a maioria das plantas do talhão se encontravam em fases diferentes nas parcelas analisadas. Formaggio e Sanches (2017) descrevem que a planta durante seu desenvolvimento passa por uma sucessão de variações nas suas quantidades de cobertura e biomassa verde. Segundo Begnini, Silva e Castelani (2013), as plantas em regiões tropicais com elevada floração em épocas de maior precipitação, como, o açazeiro, apresentam comportamento assíncrono para garantir a presença de polinizadores durante o ano.

Os pixels do talhão se mantiveram constantes, com tom de verde mais claro e com médias próximas às encontradas para os pixels extraídos da touceira, para as avaliações 2, 3, 4 e 5 (Figura 2), evidenciando que o ciclo fenológico do açazeiro teve um decréscimo mais homogêneo de biomassa. Tal característica espectral para açazeiro pode ser explicada através das observações realizadas por Rodrigues e Prazeres (2019), que constataram no açazeiro de terra firme tende a ter sincronia para os frutos verdes na estação chuvosa.

O maior valor de NDVI ocorreu na avaliação 4, apresentando média de 0,34, sendo igualmente responsivo na avaliação 1 (Tabela 3). Os valores do SAVI apresentaram o mesmo padrão que o NDVI com maiores médias na avaliação 4 e avaliação 1, apresentando média de 0,50 e 0,49 respectivamente. Isso se dá pelo fato de que os cálculos do SAVI utilizam as mesmas bandas do NDVI, diferindo apenas pela inserção do fator ajustado ao solo (*L*), que varia de acordo com a densidade de variação destacando as respostas espectrais da cultura analisada (HUETE, 1988).

Os desvios padrão dos índices nas avaliações (Tabela 3) mantiveram pouca variação entre as avaliações e com os dados uniformemente distribuídos. Alvarenga (2014) descreveu resultados semelhantes ao analisar os índices NDVI e SAVI para caracterização da cobertura vegetal, por imagem Landsat, concluindo que ambos apresentam resultados aproximados da realidade, com destaque para o SAVI, devido não possuir necessidade de medições em campo e podendo discriminar mais alvos já que apresenta maior abrangência de valores.

**TABELA 3. Médias do NDVI, SAVI, Número de Espata floral, Número de Inflorescência, Número de Cachos Verdes, Número Cachos Pretos e Número de Folhas para as avaliações 1, 2, 3, 4 e 5. Averages of NDVI, SAVI, Number of Flower Spat, Number of Inflorescence, Number of Green Bunches, Number of Black Bunches, and Number of Leaves for assessments 1, 2, 3, 4, and 5.**

Avaliações	NDVI	SAVI	Nº Espata	Nº Inflor	Nº C. Verde	Nº C.Preto	Nº Folhas
Avaliação 1	0,33±0,007ab	0,49±0,01ab	1,35±0,4b	1,89±0,5a	3,85±1,08a	0,93±0,34b	18,41±1,49a
Avaliação 2	0,33±0,002b	0,48±0,004b	1,77±0,47ab	1,41±0,59a	5,45±0,72a	1,16±0,4b	19,31±1,04a
Avaliação 3	0,32±0,003b	0,48±0,005b	2,14±0,59a	1,52±0,66a	4,94±0,78a	1,45±0,55ab	19,27±0,8a
Avaliação 4	0,34±0,004a	0,5±0,006a	2,18±0,64a	1,52±0,55a	4,31±0,69a	1,54±0,53ab	19,25±1,13a
Avaliação 5	0,33±0,004b	0,48±0,006b	2±0,6a	1,79±0,53a	3,81±1,09a	1,89±0,5a	19,56±0,62a
F(A)	3,14**	3,35**	3,83**	0,96ns	2,67ns	4,97**	1,32ns
F(B)	1,78*	2,24**	2,93**	0,44ns	0,38ns	1,52ns	0,82ns
CV(%)	1,42	1,39	26,1	36,02	27,54	33,22	5,59

Letras diferentes denotam diferenças significativas entre médias comparados no mesmo dia de avaliação. \* p-valor menor que 5%; \*\* p-valor menor que 1%; ns sem significância; F (A) - teste f - fator avaliação; F (B) - teste f - fator bloco.

A variável Número de Espata obteve a maior média na avaliação 4, seguida pela avaliação 5, avaliação 3 e avaliação 2, que foram estatisticamente iguais. Não foram observadas diferenças significativas (SNK,  $p < 0,05$ ; Tabela. 3) para número de inflorescência, número de cacho verde e número de folhas.

Para Número de Cachos Pretos ocorreu diferença significativa entre as avaliações e apresentou correlação negativa com os índices de vegetação SAVI e NDVI (Tabela 3). Tal resultado pode ser explicado pela relação fonte-dreno, que trata do transporte de assimilados da fotossíntese da planta, sendo geralmente fonte (áreas de produção de fotossintatos) uma folha adulta completamente expandida e dreno (órgãos de reserva) que na fase reprodutiva, os frutos se tornam dominantes (TAIZ; ZEIGER, 2013). Dessa forma os valores mais baixos dos índices de vegetação podem ser explicados pelas folhas do açazeiro (fonte) estarem priorizando o direcionamento de fotoassimilados para os cachos pretos (dreno), reduzindo sua biomassa e sua reflectância que, conseqüentemente, decresce os valores de NDVI e SAVI, pois a energia refletida pelos vegetais no vermelho e no infravermelho próximo são diretamente relacionadas a sua atividade fotossintética (SILVA, 2004).

TABELA 4. Correlação dos valores médios de NDVI e SAVI e das variáveis fenológicas: Número de espata Floral (Nº ESPATA), Número de inflorescência (Nº INFLORES), Número de Cacho Verde (Nº C. VERDE), Número de Cacho Preto (Nº DE C. PRETO), Número de folhas (Nº FOLHAS). **Correlation of the mean values of NDVI and SAVI and phenological variables: Number of floral spathe (Nº. SPATHE), Number of inflorescence (Nº. INFLORES), Number of Green cluster (Nº. GREEN C.), Number of Black cluster (Nº. BLACK C.), Number of leaves (Nº. LEAFS).**

	NDVI	SAVI	Nº ESPATA	Nº INFLORES	Nº F. VERDE	Nº F.PRETO	Nº FOLHAS
NDVI							
SAVI	0,99**						
Nº ESPATA	0,1245ns	0,147ns					
Nº INFLORES	-0,138ns	-0,169ns	-0,087ns				
Nº C.VERDE	-0,24 ns	-0,242ns	0,092ns	-0,229ns			
Nº C.PRETO	-0,264*	-0,236*	0,318*	0,152ns	-0,410ns		
Nº FOLHAS	0,119 ns	-0,136ns	-0,144ns	-0,277ns	-0,292ns	0,162ns	...

\* p-valor menor que 5%; \*\* p-valor menor que 1%; ns sem significância .

Para as variáveis fenológicas Número de espata, Número de inflorescência, Número de Cacho Verde, Número de folhas não houve correlação com os índices de vegetação estudados (Tabela 4), que pode estar relacionado com o abortamento de flores e frutos observado em campo, Venturiery (2014) também estudando *Euterpe oleraceae*, observou alto índice de aborto de flores, corroborado aos resultados dos estudos de Mantovani e Morellato (2000), que indica que esse é um fenômeno comum para o gênero *Euterpe*.

**CONCLUSÃO:** O número de cachos pretos apresentou correlação com os índices de vegetação NDVI e SAVI, sendo um resultado promissor para a determinação do desenvolvimento reprodutivo do açazeiro via sensoriamento remoto, levando ao produtor informações prévias de produtividade para auxílio na gestão agrícola.

## REFERÊNCIAS

ALVARENGA, A. S.; MORAES, M. F. Processamento digital de imagens LANDSAT – 8 para obtenção dos índices de vegetação NDVI e SAVI visando a caracterização da cobertura vegetal no município de Nova Lima- MG. Portal MUNDOGEO 2014. Disponível em: <https://mundogeo.com/2014/06/10/processamento-digital-de-imagens/> . Acesso em: 10 jun.2021.

- BEGNINI, R. M.; SILVA, F. R.; CASTELLANI, T. T. Fenologia reprodutiva de *Syagrus romanzoffiana* (Cham.) Glassman (Arecaceae) em Floresta Atlântica no sul do Brasil. *Biotemas*, v. 26, n. 4, 2013.
- CÂMARA, G.; SOUSA, M. Fenologia é ferramenta auxiliar de técnicas de produção. **Visão Agrícola**. Piracicaba, v. 3, n. 5, jan./jun. 2006.
- CRUZ, M. A. S.; SOUZA, A. M. B.; JESUS, J. S. Avaliação da cobertura vegetal por meio dos Índices de Vegetação SR, NDVI, SAVI e EVI na bacia do rio Japarutuba-Mirim em Sergipe. *In: Simp. Bras. Sens. Remoto*, 15. (SBSR). 2011, Curitiba. Anais. São José dos Campos: INPE, 2011. p. 1357-1364. DVD.
- FORMAGGIO, A. R.; SANCHES, I. D. Sensoriamento remoto em agricultura. São Paulo: **Oficina de Textos**, 2017. p.60 .
- HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**. Department of Soil and Water Science, University of Arizona, Tucson, Arizona, 1988.
- JENSEN, J. R. Sensoriamento Remoto do Ambiente: uma perspectiva em Recursos Terrestres. Tradução autorizada Epiphânio J. C. N. (coodernador) *et al.* São José dos Campos, SP: Parênteses, 2009. p. 15-19.
- MANTOVANI, A.; MORELLATO, P. Fenologia da floração, frutificação, mudança foliar e aspectos da biologia floral. *In: REIS, A.; REIS, M. S. Euterpe edulis Martius: biologia, conservação e manejo sustentado*. Itajaí: Herbário Barbosa Rodrigues, 2000. p. 23-38.
- MOUTINHO, M. T. Potencial do uso dos índices de vegetação de imagem de sensoriamento remoto para estimativa de produtividade da palma de óleo no estado do Pará. Orientador: Prof. Msc. João Almiro Corrêa Soares. 2018. 51f. Trabalho de Conclusão de Curso (Engenharia Cartográfica e de Agrimensura). Universidade Federal Rural Da Amazônia. – Belém, 2018.
- NASCIMENTO, W. M. O. Açaí *Euterpe oleracea* Mart. Belém-PA: **Embrapa Amazônia Oriental - Informativo Técnico Rede de Sementes da Amazônia** .2008.
- RODRIGUES, M. K. A.; PRAZERES, M. C. Avaliação fenológica de três espécies frutíferas em campo experimental da Embrapa Amazônia Oriental. Orientadora: Msc. Eunice Gonçalves Macedo. 2019. 71 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Florestal) -UFPA, Belém, 2019.
- ROUSE, J. W. *et al.* “Monitoring Vegetation Systems in the Great Plains with ERTS”. *In: Proceeding of ERTS?1 Symposium*, NASA, United States, n. 3. 1974. p. 309?317.
- SILVA, E. T. J. B. Utilização dos índices de Vegetação do Sensor MODIS para Detecção de Desmatamentos no Cerrado: Investigação de Parâmetros e Estratégias. Orientador: Prof. Laerte Guimarães Ferreira Júnior. 2004, 146 f. Dissertação (Mestrado em Geologia) – Universidade de Brasília, Brasília, 2004.
- SILVA, D. A. P. Açaí: expansão comercial e cadeia produtiva. Orientador: Edna Marisa Ramos de Castro. 2017. 49 f. Monografia (Especialização) – Universidade Federal do Pará, Núcleo de Altos Estudos Amazônicos, Programa de Pós-Graduação em Gestão Ambiental e Manejo de Paisagem, Belém, 2017.
- TAIZ, L.; ZEIGER, E. Fisiologia vegetal. 5.ed. Porto Alegre: Artemed, 2013. 954p.
- VENTURIERI, G. C. *et al.* Plano de manejo para os polinizadores do açaizeiro *Euterpe oleracea* (Arecaceae). *In: YAMAMOTO, M.; 70 OLIVEIRA, P. E.; GAGLIANONE, M. C. (Eds.). Uso sustentável e restauração da diversidade dos polinizadores autóctones na agricultura e nos ecossistemas relacionados: plano de manejo*. **Brasília: Ministério do Meio Ambiente**, 2014. p. 97–129.
- VILLAR, F. M. M; ROSAS, J. T. F; PINTO, F. A. C. Imagens e sensoriamento remoto aplicado a gestão agrícola. *In: QUEIROZ, D.M. et al (Org.). Agricultura Digital*. 1. ed. Viçosa: **Editores UFV - Universidade Federal de Viçosa**. 2020. v. 1, p. 78-79.

# SENSORIAMENTO REMOTO AÉREO E PROXIMAL PARA A PREDIÇÃO DE PRODUTIVIDADE DE MILHO FORRAGEIRO

Jussara Oliveira Gervasio<sup>1</sup>; Gabriela Maria Amaral Valiim Costa<sup>1</sup>; Samuel de Assis Silva<sup>2</sup>

<sup>1</sup>Estudante de Agronomia, Graduanda - Universidade Federal do Espírito Santo, UFES, Alegre - ES. gervasio.jussara@gmail.com / (28) 9 9977-8126; <sup>2</sup>Engenheiro Agrônomo, Professor - Departamento de Engenharia Rural, UFES, Alegre - ES

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Predizer a produtividade de culturas agrícolas auxilia na gestão de propriedades rurais. A predição pode ser feita por meio de sensoriamento remoto utilizando sensores passivos ou ativos. A partir do produto destes sensores são calculados índices de vegetação que podem ser correlacionados com produtividade da cultura, no caso do milho forrageiro, de silagem. O estudo foi conduzido no campo experimental da UFES. Para a coleta de dados foi utilizado os sensores proximais e de contato ClorofiLog e GreenSekeer e o sensor aéreo multiespectral RedEdge MX. Os índices obtidos por meio destes sensores foram IAC, NDVI(GS), NDVI, NDRE e GNDVI. Os índices de vegetação calculados em diferentes períodos, conseguiram descrever a variação temporal do vigor vegetativo das plantas, exceto o NDRE, entretanto, nenhuma das fases fenológicas avaliadas é capaz de descrever, isoladamente, a produtividade de milho forrageiro.

**PALAVRAS-CHAVE:** Índices de vegetação; Regressão múltipla; Agricultura Digital.

## AERIAL AND PROXIMAL REMOTE SENSING FOR THE PREDICTION OF FORAGE CORN YIELD

**ABSTRACT:** Predicting the yield of forage maize helps in the management of rural properties, the prediction can be done through remote sensing through the use of passive or active sensors. From the product of these sensors, vegetation indices are calculated that can be correlated with silage yield. The study was conducted in the experimental field of UFES, for data collection, the sensors ClorofiLog, GreenSekeer and Multispectral Camera RedEdge MX were used, the indices obtained through these sensors were IAC, NDVI(GS), NDVI, NDRE and GNDVI. The vegetation indices calculated in different periods were able to describe the temporal variation of the vegetative vigor of the plants, except for the NDRE, however, none of the evaluated phenological phases is able to describe, in isolation, the forage maize productivity.

**KEYWORDS:** Vegetation indices; Multiple regression; Digital agriculture

**INTRODUÇÃO:** A silagem é uma das principais opções para a alimentação animal, no Brasil, é usada como principal alimento de bovinos leiteiros, durante todo o ano para os animais que são criados em manejo intensivo, ou durante algum período para os animais que são criados em pastagens (COSTA et al., 2013). Tendo em vista a necessidade de suprir a demanda de silagem é importante, para a gestão das propriedades, ter a estimativa de produtividade de milho forrageiro, pois orientam o planejamento da logística de colheita, escoamento e armazenamento dos produtos (ANDRADE et al., 2014).

A coleta de dados para a predição pode ser feita por meio do sensoriamento remoto (HATFIELD et al. 2008), através do emprego de sensores proximais ou aéreos de vegetação, pode-se monitorar a biomassa vegetal da parte aérea (ESQUERDO et al., 2011). Os sensores podem ser passivos, os que necessitam de fonte de radiação eletromagnética externa para o funcionamento, como as câmeras multiespectrais acopladas em VANT's, ou sensores ativos que emitem energia eletromagnética e detectam parte desta energia que é refletida por estes na direção destes sensores, como o GreenSekeer e o ClorofiLog.

A partir dos produtos resultante destes sensores é possível obter os índices de vegetação, que são calculados a partir da reflectância dos comprimentos de onda do espectro do visível e do infravermelho, e estes apresentam relação com o estado fisiológico das plantas (WÓJTOWICZ et al., 2016). Os índices de vegetação vêm sendo

utilizados em diversos estudos na cultura do milho nos quais podem ser correlacionados com o estado nutricional (ANDRADE JÚNIOR et al., 2021a), com estádios de desenvolvimento (ANDRADE et al., 2019), com o estado hídrico (ANDRADE JÚNIOR et al., 2021b) e também com a produtividade da cultura (MATIAS et al., 2015). Desse modo objetivou-se utilizar produtos obtidos por meio do sensoriamento remoto aéreo e proximal para descrever o comportamento temporal e prever a produtividade do milho forrageiro a partir da descrição da correlação entre os Índices de Vegetação e os valores absolutos do rendimento.

**MATERIAIS E MÉTODOS:** O experimento foi conduzido no campo experimental da Universidade Federal do Espírito Santo (UFES) no município de Alegre – Espírito Santo, em uma área plana de cultivo de milho (*Zea mays* L.) com aproximadamente 2,4 ha. Na área foram semeados dois híbridos de milho, o SHS 5570 RR e GLYFOS. A semeadura foi realizada nos dias 25, 26, 27, 28 e 29 de outubro, com espaçamento de 1 metro entre linhas e 6 a 8 sementes por metro. Foram demarcados 20 pontos amostrais aleatórios, compostos por doze plantas.

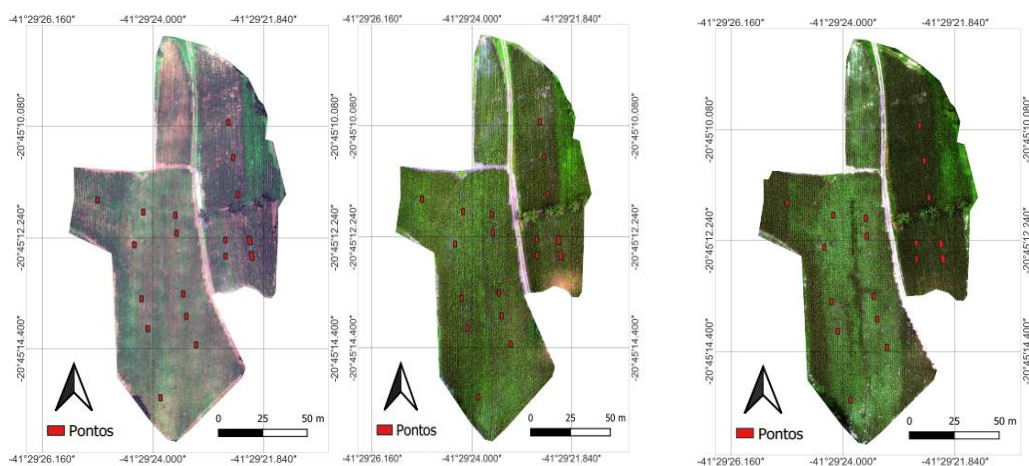
As amostragens se concentraram nas fases V10 (10 folhas totalmente desenvolvidas), VT (pendoamento) e R2 (estádio reprodutivo, “grão-bolha-d’água”), correspondendo as 5<sup>a</sup>, 7<sup>a</sup> e 10<sup>a</sup> semanas após a semeadura, respectivamente. Foram realizadas leituras com o Greenseeker™, sensor ótico de vegetação para determinação do Índice de Vegetação da Diferença Normalizada [NDVI(GS)]. Foram determinadas ainda o Índice Aparente Foliar de Clorofila (IAC) utilizando um clorofilômetro da marca ClorofiLOG para determinação dos índices de clorofila A (IAC-A), B (IAC-B) e total (IAC-T). Nos mesmos períodos de avaliações *in loco* foram realizados aerolevantamentos, onde utilizou-se um sensor ótico multiespectral RedEdge MX embarcado em Veículo Aéreo não Tripulado (Vant) modelo Inspire 2. O VANT foi operado em voos automatizados, há 80 metros de altura, com sobreposições frontais e laterais de 80%. Para os mapeamentos foram utilizados pontos de controle e de verificação (fotointerpretáveis) e distribuídos de forma estratégica por toda a extensão da área.

As imagens obtidas foram processadas utilizando o software OpenDroneMap, onde os ortomosaicos foram construídos e em seguida a calibração radiométrica e geométrica das imagens. Após a calibração, as imagens foram processadas utilizando o software QGIS, onde foi feito o georreferenciamento dos ortomosaicos, com base nos pontos de apoio. Na sequência, foram extraídos os valores dos comprimentos de onda de cada banda espectral para cada ponto amostral, utilizando a ferramenta Estatísticas Zonais, a partir de um arquivo vetorial de pontos (contendo as coordenadas geográficas dos pontos). Após a extração dos valores dos comprimentos de onda de cada banda espectral foram calculados os índices de vegetação. Nesse trabalho foram utilizados três índices de vegetação capazes de descrever o comportamento do vigor vegetativo das plantas, que pode ser calculados conforme as equações:

Índices de vegetação	Fórmula
Índice de Vegetação por Diferença Normalizada (NDVI)	$\frac{NIR - Red}{NIR + Red}$ Eq. (1)
Índice de Borda Vermelha de Diferença Normalizada (NDRE)	$\frac{NIR - Red}{NIR + Red}$ Eq. (2)
Índice de vegetação por diferença normalizada na banda do verde (GNDVI)	$\frac{(NIR - Green)}{(NIR + Green)}$ Eq. (3)

## RESULTADOS E DISCUSSÃO: RESULTADOS E DISCUSSÃO:

A evolução vegetativa da cultura, bem como a distribuição dos pontos amostrais pode ser observada na Figura 1.



(A) (B) (C)

Figura 1 – Imagens aéreas obtidas com Vant da área em estudos nos diferentes períodos. (A) Leitura 1 (V10); (B) Leitura 2 (VT); (C) Leitura 3 (R2).

Na Figura 3 estão apresentados os valores do índice aparente de clorofila foliar (IAC) A, clorofila B e clorofila Total das plantas de milho nos diferentes períodos de leitura.




Figura 3. Médias e intervalo de confiança para o índice foliar aparente de clorofila foliar A, B e Total. L1 – leitura 1; L2 – leitura 2, e; L3 – leitura 3.

Para o IAC-A houve grande elevação nos teores da L1 para a L2, seguido por um decréscimo para a L3. Para o IAC-B o comportamento foi semelhante ao do IAC-A entre L1 e L2, entretanto, para L3 o valor médio foi idêntico ao da L2, apesar de uma maior amplitude. O comportamento IAC-T acompanhou o da IAC-A, conforme esperado, tendo em vista que a relação entre clorofila A e B é, naturalmente, de 3:1 (STREIT, 2005), logo, quem domina a resposta da clorofila total é a clorofila A. O comportamento da IAC-A encontrado neste trabalho pode estar relacionado a dois fatos distintos. O primeiro diz respeito a condições fisiológicas inerentes à cultura, ou seja, em fases reprodutivas os excedentes de fotoassimilados acumulados durante as fases vegetativas são mobilizados para o enchimento de grãos (FANCELLI, 2015). Como as leituras em L3 foram realizadas após o pendoamento e quando as espigas estão com os grãos na fase de “bolha d’água”, pode ter acontecido uma translocação de fotoassimilados das folhas para os frutos, reduzindo os valores de IAC-A. O segundo fato diz respeito à possíveis estresses, sejam eles bióticos e/ou abióticos que comprometeram o desenvolvimento das plantas. Como não foi realizada nenhuma avaliação nutricional e ou fitossanitária, essa última justificativa é apenas uma hipótese.

Na Figura 4 estão representados os comportamentos dos índices de vegetação multiespectrais.

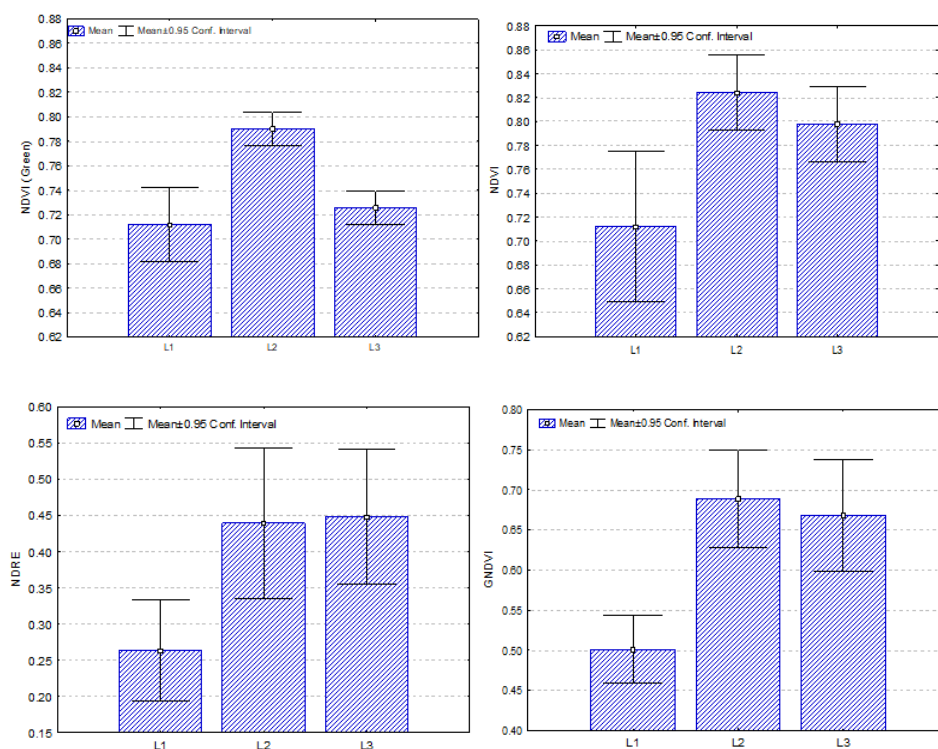


Figura 4. Médias e intervalo de confiança para os índices de vegetação determinados a partir do GreenSeeker (NDVI) e da RedEdge MX (NDVI, NDRE e GNDVI). L1 – leitura 1; L2 – leitura 2, e; L3 – leitura 3.

Os índices de vegetação, com exceção do NDRE, apresentaram um comportamento semelhante ao discutido para o IAC-A, com aumento entre L1 e L2 e redução em L3. Apesar desse fato, somente para o NDVI(GS) houve diferença estatisticamente significativa entre as leituras L2 e L3. Em todos os índices e sensores, houve um pico de valores no estágio fenológico compreendido na leitura L2. Esse fato é explicado pelo aumento da biomassa do milho até o estágio fenológico do florescimento, e em seguida a redução desses valores até a maturação completa (DUAN et al., 2017). O NDVI(GS) e o NDVI obtido por meio da RedEdge MX, apresentam comportamento semelhantes nos três períodos de leitura, nota-se que os resultados para L1 e L2 possuem amplitudes que se sobrepõem. Em L3 não há sobreposição das amplitudes, o que significa que nessas leituras os valores são estatisticamente diferentes.

Tabela 2. Correlação linear de Pearson entre a matéria seca e índices mensurados nos diferentes períodos.

Variável	M. Seca		
	L1	L2	L3
IAC-A	<b>0.40</b>	0.02	0.02
IAC-B	<b>0.44</b>	<b>0.50</b>	0.16
IAC-T	<b>0.42</b>	0.30	0.09
NDVI(GS)	-0.08	<b>0.52</b>	0.19
NDVI	<b>0.39</b>	0.25	<b>0.44</b>
NDRE	<b>0.41</b>	<b>0.42</b>	0.31
GNDVI	<b>0.40</b>	0.20	<b>0.57</b>

Negrito é significativo ao nível de 5% de probabilidade. L1 – leitura 1; L2 – leitura 2, e; L3 – leitura 3.

Por meio da análise das informações apresentadas na tabela é possível observar que todas as correlações significativas entre os índices de vegetação e a biomassa do milho são positivas, ou seja, os incrementos nos valores da produtividade estão associados a incrementos nos valores dos índices de vegetação. Nota-se, que grande parte das variáveis que apresentaram correlação significativa com a produtividade de matéria seca do milho foram mensuradas no período da L1 (estádio V10). Nesse estágio as plantas definem o tamanho das espigas e apresentam alta exigência de água e nutrientes (MAGALHÃES e DURÃES, 2006), portanto, prever a produtividade nesse estágio pode permitir a correção do manejo da lavoura e conseqüentemente aumentar a produtividade final.

Em L1 os IAC-A, IAC-B e IAC-T e os índices de vegetação obtidos a partir dos produtos de sensoriamento remoto aéreo se correlacionaram com a matéria seca de silagem. Para o NDVI(GS) a ausência de correlação com a matéria seca nos períodos L1 e L3 pode se justificar, respectivamente, pela elevada amplitude de variação e os baixos valores absolutos. Esse fato indica que, apesar de ser um sensor proximal (menos suscetível a variações na atmosfera), o índice gerado nem sempre será capaz de descrever o comportamento de distribuição da produtividade da cultura, apesar da eficiência em avaliar o vigor vegetativo das plantas.

No período L2 há correlação entre os índices de vegetação IAC-B, NDVI(GS) e NDRE com a produtividade do milho, enquanto que, em L3, os índices de vegetação que apresentaram correlação com a produtividade foram NDVI e GNDVI, ambos calculados a partir dos produtos de sensoriamento remoto aéreo. Apesar da correlação não ser capaz de estabelecer relações de causalidade entre variáveis, valores significativos são importantes para descrever a similaridade na distribuição de diferentes conjuntos de dados. Quando esses, sabidamente, são interligados, ou seja, sendo um reposta do outro, é possível entender a correlação como uma análise que explicita efeitos simultâneos (DJORDJEVI? et al., 2021).

O NDRE não apresentou correlação significativa com a matéria seca do milho apenas na L3. Nos demais períodos a correlação foi positiva e significativa, conforme já comentado. Esse resultado corrobora o discutido anteriormente sobre a incapacidade desse índice, na fase R2, em descrever as variações ocorridas na lavoura, reforçando o fato de que na transição entre fase vegetativa para reprodutiva ele perdeu a capacidade de segmentar o comportamento das plantas.

Todos os índices de vegetação que apresentaram correlação significativa com a matéria seca do milho foram utilizados para a predição de produtividade da cultura. Para tal foram utilizados modelos de regressão linear múltipla e polinomial de segundo grau. Os modelos construídos para cada plataforma de coleta de dados e período de leitura e para a combinação destes são apresentados na Tabela 3.

Tabela 3. Modelos de regressão linear e polinomial para predição da biomassa de milho forrageiro a partir dos índices de vegetação de diferentes sensores, e Erro médio absoluto (MAE) e erro relativo (ER) da predição de biomassa de milho forrageiro por meio de diferentes modelos de regressão.

Plataforma	Modelo	R <sup>2</sup> (%)	MAE	ER (%)
L1				
VANT	$Y = -1.5132 + 3.7760 * NDVI + 2.8585 * NDRE + 4.3753 * GNDVI$	24,26	9,43	36,64
	$Y = -2.6584 - 15.1445 * NDVI + 15.5769 * NDVI^2 + 49.2870 * NDRE - 69.3837 * NDRE^2 + 7.9539 * GNDVI - 5.5777 * GNDVI^2$	59,37	6,20	23,01
Clorofila	$Y = 17.3201 - 0.6716 * ClorA + 1.1701 * ClorB$	24,33	8,65	36,88
	$Y = 930.5059 - 73.9462 * ClorA + 3.2024 * ClorA^2 + 90.4357 * ClorB + 3.7608 * ClorB^2 - 1.7450 * ClorT^2$	34,47	8,18	36,96
L2				
VANT	$Y = 2.2652 + 4.2236 * NDRE$	17,93	9,73	40,33



	$Y=1.4145+9.3778*NDRE-6.0510*NDRE^2$	19.07	9,89	36,49
Clorofila	$Y=-2.3263+0.4959*ClorB$	28.04	9,44	40,33
	$Y=6.5091-0.9360*ClorB+0.0564*ClorB^2$	29.94	8,73	39,81
GreenSeeker	$Y=-24.5122+36.0005*NDVI(Green)$	25.73	8,87	40,07
	$Y = 675.3967-1747.7531*NDVI(Green)+1135.0104*NDVI(Green)^2$	39.95	7,49	33,23
L3				
VANT	$Y=0.9138-4.4324*NDVI3+10.0895*GNDVI3$	32.62	7,94	28,62
	$Y= -74.3861+170.2952*NDVI-106.3671*NDVI^2+25.2603*GNDVI-13.1984*GNDVI^2$	37.10	8,08	31,49
L1 x L2				
VANT	$Y=-2.1174+4.8482*NDVI1+1.9676*NDRE1+1.4768*GNDVI1+3.4783*NDRE2$	34.30	8,42	36,68
	$Y= 4.0-13.7049*NDVI1+15.4612*NDVI1^2+46.5032*NDRE1-65.5221*NDRE1^2-19.4486*GNDVI1+17.3831*GNDVI1^2+1.0730*NDRE2+0.4596*NDRE2^2$	59.87	7,64	32,13
Clorofila	$Y=18.1792-0.8220*ClorA1+1.1220*ClorB1+0.4041*ClorB2$	35.43	8,86	35,69
	$Y= 1055.8764-83.1037*ClorA+3.5124*ClorA^2+98.66*ClorB+4.0298*ClorB^2-1.8919*ClorT1^2+0.2122*ClorB2+0.0093*ClorB2^2$	47.85	6,07	22,67
L1 x L3				
VANT	$Y=4.0750+6.6330*NDVI1-0.2133*NDRE1+2.4341*GNDVI1-18.6180*NDVI3+13.4854*GNDVI3$	45.81	7,10	25,35
	$Y= -135.5357+11.4931*NDVI1-7.1074*NDVI1^2+52.1809*NDRE1-72.1957*NDRE1^2+45.1558*GNDVI1-40.3631*GNDVI1^2+323.3818*NDVI3-208.4670*NDVI3^2-37.5342*GNDVI3+34.6704*GNDVI3^2$	76.74	5,08	20,71
L2 x L3				
VANT	$Y=1.3936+2.9671*NDRE2-6.2004*NDVI3+9.5319GNDVI3$	40.69	7,82	29,80
	$Y= -182.3927-16.9990*NDRE2+23.1608*NDRE2^2+455.2547*NDVI3-275.2893*NDVI3^2+1.2565*GNDVI3+1.6675*GNDVI^256$	51.50	8,01	34,55
L1 x L2 x L3				
VANT	$Y= 5.3578+8.2002*NDVI1-0.7368*NDRE1-0.4422*GNDVI+3.5405*NDRE2-22.0776*NDVI3+14.0617*GNDVI3$	55.89	6,86	27,46
	$Y= -179.7716+11.8199*NDVI1-7.8686*NDVI^2+50.3784*NDRE1-69.1872*NDRE1^2+41.7664*GNDVI1-37.3562*GNDVI1^2-9.3107*NDRE2+11.0714*NDRE2^2+440.7736*NDVI3-276.3288*NDVI3^2-45.1950*GNDVI3+38.8616*GNDVI^2$	77.88	4,96	20,34

MAE = Erro médio absoluto ( $\text{ton}\cdot\text{ha}^{-1}$ ); ER = Erro relativo; NDVI(GS) = GreenSeeker; L1 – leitura 1; L2 – leitura 2, e; L3 – leitura 3.

Analisando as leituras individualmente, observa-se que para L1 o modelo que melhor descreveu o comportamento da produtividade em relação aos índices de vegetação é o modelo polinomial, gerado a partir dos índices calculados para o produto do sensoriamento remoto aéreo, apresentando um  $R^2$  de 59,37%. Em L2 o modelo que apresenta maior  $R^2$  é o modelo polinomial do NDVI(GS). Nesse período e para os modelos obtidos pelo produto do sensoriamento remoto aéreo e do IAC não se observou grandes ganhos nos valores de  $R^2$  para a regressão polinomial quando comparada à regressão linear múltipla. Nesse contexto, não existe uma justificativa para a utilização dos modelos polinomiais em detrimento aos lineares, que são mais simples de serem implementados e também compreendidos. Comportamento semelhante foi observado em L3, em que os valores de  $R^2$  para ambos os métodos de análise de regressões são próximos, justificando a utilização do modelo mais simples para a predição da produtividade.

Para os modelos ajustados para a combinação de variáveis mensuradas em diferentes períodos de leitura, foram considerados apenas aqueles que se correlacionaram com a produtividade em diferentes leituras. Nesse caso, a maioria dos modelos contemplam apenas índices advindos do sensoriamento remoto aéreo, com exceção da combinação L1 x L2 onde se ajustou modelos para o IAC. Para os modelos resultantes das combinações os que apresentaram maior  $R^2$  foram os modelos polinomiais. Os maiores valores de  $R^2$  foram observados em L1 x L3 ( $R^2 = 76,74\%$ ) e L1 x L2 x L3 ( $R^2 = 77,88\%$ ). Em todas as combinações de períodos de leitura, foram obtidos coeficientes de determinação maiores para os modelos polinomiais, comportamento atribuído a melhora do desempenho das regressões polinomiais na avaliação dos atributos de entrada (PANG et al., 2021).

Os valores de MAE variaram entre 4,96 e 9,89  $\text{ton}\cdot\text{ha}^{-1}$ , ou seja, essa é a variação da diferença absoluta entre os valores preditos pelos modelos e o valores observados em campo (WILLMOTT e MATSUURA, 2005). Se considerarmos o desvio padrão ( $S = 13,61 \text{ ton}\cdot\text{ha}^{-1}$ ) como o limite aceitável de variação absoluta para os modelos de predição de produtividade, temos que todos os modelos podem ser aceitos para estimar a produtividade. No entanto é recomendável que se opte por modelos que apresentem o menor MAE.

Em L1 o modelo que apresenta o menor MAE é o polinomial construído com todos os índices (NDVI, NDRE e GNDVI) calculados a partir dos produtos de sensoriamento remoto aéreo e com o erro absoluto de 6,20  $\text{ton}\cdot\text{ha}^{-1}$ . Para L2 o menor MAE é obtido pela regressão polinomial construída a partir do NDVI(GS), sendo a variação de 7,49  $\text{ton}\cdot\text{ha}^{-1}$ . Esses resultados podem ser corroborados pelos valores de  $R^2$ , apresentados e discutidos acima, onde as regressões com maior  $R^2$ , apresentaram menores MAE. Em L3 o modelo que apresenta menor MAE é o linear, sendo este valor próximo ao calculado para o modelo polinomial (7,94  $\text{ton}\cdot\text{ha}^{-1}$  e 8,08  $\text{ton}\cdot\text{ha}^{-1}$ , respectivamente). Esse resultado é corroborado pelos valores de  $R^2$  para esse período, conforme discutido anteriormente.

Quando são utilizadas combinações de períodos tem-se uma redução dos valores de MAE, os menores valores foram de 4,96  $\text{ton}\cdot\text{ha}^{-1}$ , 5,08  $\text{ton}\cdot\text{ha}^{-1}$  e 6,07  $\text{ton}\cdot\text{ha}^{-1}$ , para as L1 x L2 x L3, L1 x L3 e L1 x L2, respectivamente. Apenas para a combinação L2xL3 não houve redução do MAE, quando comparados aos modelos gerados para os períodos individualmente. Esses resultados reforçam o fato de que, modelos que contemplam um maior número de informações tendem a produzir estimativas mais assertivas, reduzindo a incerteza das predições (SILVA et al., 2011).

Os resultados do ER são semelhantes aos resultados do MAE. Em L1 o menor ER foi de 23,01% para a regressão polinomial para o VANT, em L2 o menor ER, 33,23%, foi encontrado para a regressão polinomial para o NDVI(GS) e, em L3, o menor valor de ER foi para a regressão linear, 28,62%, sendo este valor próximo ao valor de ER do modelo polinomial, 31,49%. Para as combinações entre períodos os valores de ER foram menores do que em períodos individuais, exceto para a combinação L2xL3. Nas combinações os melhores resultados são obtidos para as regressões polinomiais para o VANT, sendo os menores valores obtidos para L1 x L2 x L3, L1 x L3 e L1 x L2.

Em linhas gerais os valores de ER variaram entre 20,34 e 40,33% para os modelos de predição de produtividade o que, quando comparados ao CV (51,90%), podem ser considerados aceitáveis para descrever o comportamento observado. Leal et al. (2015) estudando diferentes modelos para a predição de biomassa de milho encontraram erros percentuais de 23,25% para a regressão.

Os resultados dos avaliadores de desempenhos dos modelos corroboram a discussão apresentada anteriormente, em que os modelos que apresentaram os menores erros (MAE e ER) foram os mesmo que apresentaram os maiores coeficientes de determinação. O que indica que estes são os modelos que perdem menos informações, ou seja, descrevem melhor a variação da variável dependente em relação as variáveis independentes.

**CONCLUSÃO:** Os índices de vegetação calculados em diferentes períodos, conseguiram descrever a variação temporal do vigor vegetativo das plantas, exceto o NDRE.

Foi possível utilizar produtos de sensoriamento remoto aéreo para a predição de produtividade de milho forrageiro.

Os modelos polinomiais tiveram melhor desempenho que os lineares para predição de biomassa de milho utilizando, como variáveis independentes, índices de vegetação calculados a partir de produtos de sensoriamento remoto aéreo.

Nenhuma das fases fenológicas avaliadas é capaz de descrever, isoladamente, a produtividade de milho forrageiro.

### REFERÊNCIAS

ANDRADE JUNIOR, A.S., BASTOS, E.A., SOUSA, C.A.F., CASARI, R.A.D.C.N. RODRIGUES, B.H.N. AVALIAÇÃO DO ESTADO HÍDRICO DE CULTIVARES DE MILHO POR IMAGENS AÉREAS. **Revista Caatinga**, 34(2), pp.432-442. 2021b.

ANDRADE JUNIOR, A.S.D., MELO, F.D.B., BASTOS, E.A.; CARDOSO, M.J. Avaliação do estado nutricional do milho por índices de vegetação de imagens aéreas. **Ciência Rural**, 51. 2021a.

ANDRADE, R.G.; SEDIYAMA, G.C.; SOARES, V.P.; GLERIANI, J.M.; MENEZES, S.J.M.C. Estimativa da produtividade da cana-de-açúcar utilizando sebal e imagens Landsat. **Revista Brasileira de Meteorologia**, v.29, n.3, 433 - 442, 2014.

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), pp.1501-1511. 1994.

COSTA, J. H. C., M. J. HÖTZEL, C. LONGO, AND L. F. Balcão. A survey of management practices that influence production and welfare of dairy cattle on family farms in southern Brazil. **J. Dairy Sci.** 96:307–317. 2013.

DJORDJEVIĆ, B.; MANE, A. S.; KRMAC, E. Analysis of dependency and importance of key indicators for railway sustainability monitoring: A new integrated approach with DEA and Pearson correlation. **Research in Transportation Business & Management**. v. 41, e. 100650, 2021.

DUAN, T. et al. Dynamic monitoring of NDVI in wheat agronomy and breeding trials using an unmanned aerial vehicle. **Field Crops Research**. Amsterdam, v. 210, p. 71–80, 2017.

ESQUERDO, J. C. D. M.; ZULLO, J.; ANTUNES, J. F. G. Use of NDVI/ AVHRR time-series profiles for soybean crop monitoring in Brazil. **International Journal of Remote Sensing**, Basingstoke, v. 32, n. 3, p. 3711-3727, 2011.

FANCELLI, A.L., 2015. Manejo baseado na fenologia aumenta eficiência de insumos e produtividade. **Visão Agrícola**, 13(1), pp.24-29.

HATFIELD, J. L. et. al. Application of spectral remote sensing for agronomic decisions. **Agronomy Journal**, Madison, v. 100, p. 117-131, 2008.

MAGALHAES, P.C. AND DURÃES, F.O. Fisiologia da produão de milho. Embrapa Milho e Sorgo-**Circular Tcnica** (INFOTECA-E). 2006.

MATIAS, J.F.G., STRECK, L. AND AGUILAR, D.D. Geraão de mapas de produtividade de milho (*Zea mays*) com ndice de vegetaão NDVI de imagens Landsat 8. **XVII Simpsio Brasileiro de Sensoriamento Remoto (SBSR)**, Joo Pessoa-PB. Anais, So Jos dos Campos: INPE, pp.157-162. 2015.

PIMENTEL-GOMES, F. **Curso de estatstica experimental**. 15. ed. Piracicaba: Fealq, 2009, 451p.

PANG, Y.; SHI, M.; ZHANG, L.; SONG, X.; SUN, W. PR-FCM: a polynomial regression-based fuzzy c-means algorithm for attribute-associated data. **Information Sciences**, V. 585, P. 209-231, 2021.

SILVA, S.A.; LIMA, J.S.S.; OLIVEIRA, R.B. Modelo agrometeorolgico na estimativa da produtividade de duas variedades de caf arbica considerando a variabilidade espacial. **Irriga**, v. 16, n. 1, p. 1-10, 2011.

WILLMOTT, C. J.; MATSUURA, K. Advantages of the mean absolute error (mae) over the root mean square error (rmse) in assessing average model performance. **Climate Research**, V. 30, N. 1, P. 79-82, 2005.

WJTOWICZ, M.; WJTOWICZ, A.; PIEKARCZYK, J. Application of remote sensing methods in agriculture. **Communications in Biometry and Crop Science**, v. 11, p. 31-50, 2016.

# AERONAVE REMOTAMENTE PILOTADA PARA O PLANEJAMENTO DE PLANTIO DE CAFÉ

**Lucas Santos Santana<sup>1</sup>; Gabriel Araújo e Silva Ferraz<sup>4</sup>; Nicole Lopes Bento<sup>2</sup>; Sabrina Aparecida Teodoro<sup>3</sup>; Rafael de Oliveira Faria<sup>5</sup>**

<sup>1</sup>Eng° Agrônomo, Doutorando em Engenharia Agrícola - Escola de Engenharia Agrícola, Universidade Federal de Lavras (UFLA) Caixa Postal 3037 ? 37200-000 ? Lavras, MG ? Brasil.

lucas.unemat@hotmail.com / (35) 9 9897-3964; <sup>2</sup>Eng° Ambiental, Doutorando em Engenharia Agrícola - Escola de Engenharia Agrícola, Universidade Federal de Lavras (UFLA) Caixa Postal 3037 ? 37200-000 ? Lavras, MG ? Brasil; <sup>3</sup>Eng° Agrícola, Estudante Engenharia Agrícola - Escola de Engenharia Agrícola, Universidade Federal de Lavras (UFLA) Caixa Postal 3037 ? 37200-000 ? Lavras, MG ? Brasil; <sup>4</sup>Eng° Agrícola, Professor - Escola de Engenharia Agrícola, Universidade Federal de Lavras (UFLA) Caixa Postal 3037 ? 37200-000 ? Lavras, MG ? Brasil; <sup>5</sup>Eng° Agrícola, Professor - Escola de Engenharia Agrícola, Universidade Federal de Lavras (UFLA) Caixa Postal 3037 ? 37200-000 ? Lavras, MG ? Brasil

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Informações sobre o uso e ocupação do solo são essenciais para a implantação de cafezais. Essa etapa consiste no planejamento de linhas de plantio e estradas secundárias (carreadores), auxiliados por dados cartográficos consistentes. Diante dessa premissa os Modelos Digitais de Terreno (MDTs) obtidos de Sistemas de Aeronaves Remotamente Pilotadas (ARP) podem contribuir para a coleta eficiente de dados para topografia tornando esta técnica aplicável a projetos de cafeicultura de precisão. Dessa forma, esta pesquisa tem como objetivo avaliar o plantio de uma área cafeeira sem o levantamento prévio do terreno no plantio e verificar a capacidade de planejamento para formação de nova lavoura por meio de dados de aeronaves remotamente pilotada. A área de estudo compreende um cultivo comercial de 16,3 hectares, cultivada com cafeeiro de aproximadamente 20 anos. Inicialmente as imagens foram capturadas por meio de uma aeronave remotamente pilotada (ARP), modelo Phantom 4 Advance, em seguida foram submetidas a processamento no software Photoscan 1.4 para obtenção dos modelos digitais de terreno e planejamento de linhas de plantio e carreadores. Os resultados demonstraram que o planejamento de plantio por modelos digitais oriundos de ARPs foram eficientes. O uso e ocupação do solo caracterizado pelo índice de vegetação MPRI apresentou 11,1% da área ocupada por carreadores, após o planejamento das linhas a aérea otimizada apresentou 1,6 % de ocupação por estradas secundárias (carreadores). Diante disso, as ARPs podem ser importantes ferramentas para o planejamento do plantio de cafeeiro. A aplicação de produtos cartográficos obtidos por Aeronaves Remotamente pilotadas para o planejamento de linhas de plantio e otimização de uso do solo foi satisfatório. Demonstrando otimização de 10% no uso do solo.

**PALAVRAS-CHAVE:** Declividade; Drone; Sensoriamento Remoto

## REMOTELY PILOTED AIRCRAFT FOR COFFEE PLANTING PLANNING

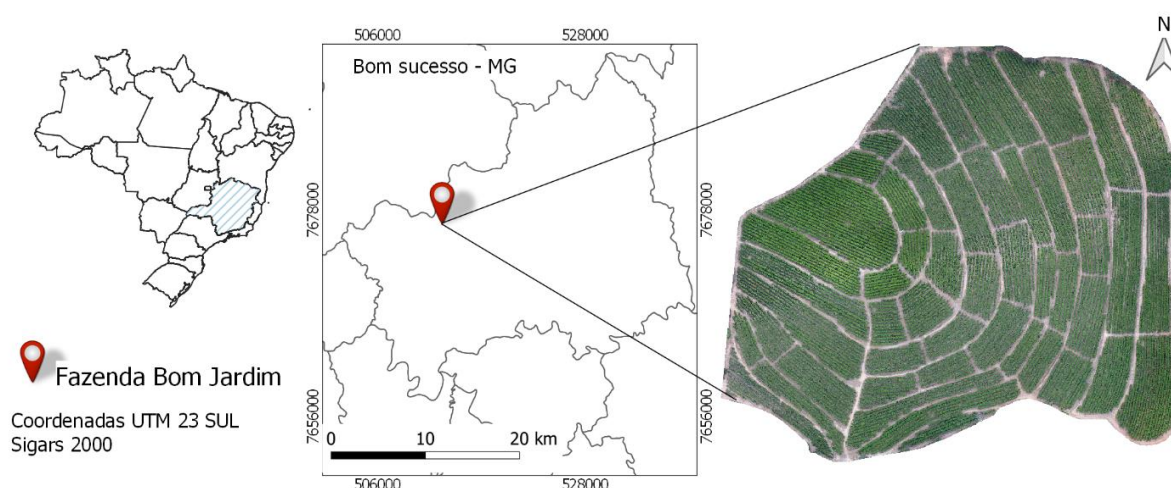
**ABSTRACT:** Information on land use and occupation is essential for coffee plantations' establishment. This step consists of planning planting lines and secondary roads (carreadores), aided by consistent cartographic data. Given this premise, Digital Terrain Models (DTMs) obtained from Remotely Piloted Aircraft Systems (RPA) can contribute to the efficient collection of data for topography, making this technique applicable to precision coffee projects. Thus, this research aims to evaluate a coffee area planting without a previous survey at planting and verify the planning capacity for forming a new crop through data from remotely piloted aircraft. The study area comprises a commercial crop of 16.3 hectares, cultivated with coffee trees for approximately 20 years. Initially, the images were captured utilizing a remotely piloted aircraft (RPA), model Phantom 4 Advance, then they were submitted to processing in the software Photoscan 1.4 to obtain the digital terrain models. The results showed that planting planning using digital models from PRAs was efficient. The land use and occupation characterized by the MPRI index showed occupation by carriageways of 11.1% before the renovation. After planning from cartographic data of the MDEs, the optimized area showed 1.6% of employment by secondary roads (carriers). Therefore, RPAs can be essential tools for coffee plantations'

planning. The application of cartographic products obtained by Remotely Piloted Aircraft for planting lines planning and land use optimization was satisfactory. They were demonstrating 10% optimization in land use.

**KEYWORDS:** Slope; Drone; Remote Sensing

**INTRODUÇÃO:** A cafeicultura representa uma das atividades agrícolas mais importantes para o Brasil (SARA et al 2019). Técnicas de manejo na cafeicultura têm sido aprimoradas com o intuito de aumentar a produtividade e reduzir custos. Nesse contexto surge um conjunto de tecnologias para auxiliar o produtor no manejo da lavoura conhecido como cafeicultura de precisão, visando maximizar a rentabilidade, aumentar eficiência da adubação, pulverização e colheita, culminando na elevação da produtividade e da qualidade final do produto (Ferraz et al., 2012). Mesmo com todo avanço em técnicas de manejo eficiente na cafeicultura, muitas tecnologias ainda continuam emergentes, inseridas para aumentar a produtividade e reduzir custos. Ferramentas de sensoriamento remoto permitem o acompanhamento próximo e frequente em diversas culturas, melhorando a qualidade no gerenciamento e manuseio das aplicações agrícolas (MOREIRA et al 2019, SANTOS et al 2019a) e fazem parte do monitoramento das lavouras cafeeiras (Chemura et al., 2018). O uso de aeronaves remotamente pilotadas (ARP) é explorado sistematicamente devido a sua alta resolução espacial e temporal (Santana et al., 2019). Na cafeicultura de precisão vários produtos oriundos de imagens aéreas são utilizados para fins de monitoramento e planejamento. O modelo digital de elevação (MDE) representa um desses produtos, agregando informações de altitude para o terreno. Nesse processo é obtida a altitude de cada pixel para calcular a elevação dos elementos presentes na área, possibilitando desenvolver um modelo que leva em conta todos os elementos em três dimensões presentes no terreno (RUMPLER 2013). Portanto esse tipo de mapeamento pode contribuir no planejamento da cafeicultura. Os campos cafeeiros em sua maioria estão presentes em regiões com alta declividade, e essa característica pode alterar a qualidade do plantio. Como os levantamentos clássicos de topografia são considerados de alto custo, muitos produtores optam por desenvolver sua própria técnica de plantio em declividade. Entretanto essas formas de plantio podem não ser eficientes para o melhor aproveitamento da área. Dessa forma, esta pesquisa tem como objetivo avaliar o uso de ocupação do solo de uma área cafeeira sem o levantamento topográfico realizado na etapa de plantio e verificar a capacidade de modelos digitais de elevação obtidos por ARPs no planejamento de linhas de plantio e otimização quanto a locação de carregadores.

**MATERIAIS E MÉTODOS:** A região de estudo compreende uma área comercial de 16,3 hectares. Nesse experimento encontra-se implantado uma lavoura cafeeira de aproximadamente 20 anos. A propriedade rural denominada Fazenda Bom Jardim (Figura 01) está situada no município de Santo Antônio do Amparo, Minas Gerais, sob as coordenadas 21°00'55.55" S e 44°54'57.75" O.



**FIGURA 1. Localização da área de estudo, fazenda Bom Jardim, município de Santo Antônio do Amparo MG. Study area location, Bom Jardim Farm, municipality of Santo Antônio do Amparo, MG, BRAZIL.**

A imagens foram capturadas por meio de uma aeronave remotamente pilotada (ARP), modelo Phantom 4 Advance com Sistema de Posicionamento GPS/GLONASS equipado com sensor CMOS de 1 polegada para

capturar fotos de até 20 megapixels. O planejamento de voo se iniciou com o reconhecimento da área, para definir as configurações do plano de voo: em seguida, foi definido o ponto de pouso e decolagem, denominado “home”. Verificou-se também as condições climáticas do ambiente como quantidades de nuvens, níveis de insolação, velocidade do vento e presença de pássaros conforme indicado por SANTOS et al (2019b).

Os voos foram realizados no horário de 12:00 horas por questões de baixa presença de nuvens e pouca interferência de sol. A missão foi definida com as seguintes características de plano de voo: altura de 30m, velocidade 3m/s<sup>-1</sup> e sobreposição lateral e longitudinal de 80%, obtendo uma resolução espacial de 1,68cm em três bandas espectrais Red, Green e Blue (RGB).

As imagens aéreas foram processadas utilizando o software Agisoft PhotoScan 1.4. Para o processamento foram necessárias as seguintes etapas: alinhamento das imagens pelo processo de foto-triangulação, construção de nuvem de pontos esparsa, densificação da triangulação, aplicação textura, construção MDE e ortomosaico que representam todas as imagens coletadas. Os valores dos parâmetros utilizados no processamento dos dados são descritos na Tabela 1.

**TABELA 1. Parâmetros utilizados para formação do orthomosaico e modelo digital de elevação. Parameters used to form the orthomosaic and digital elevation model.**

Parâmetros	Configurações	Parâmetros	Configurações
<b>Align Photos</b>		<b>Build ORTOMOSAIC</b>	
Accuracy	Highest	Mode Combination	Mosaic
Pair preselection	Disable	Surface	Mesh
<b>Build Dense Cloud</b>		<b>Build MDT</b>	
Quality	Medium	Class	
Depth filtering	Aggressive	From	Any Class
<b>Build Mesh</b>			
Surface Type	Arbitrary		

Após a construção do MDE, o mesmo foi submetido ao processamento em software SIG para obtenção de dados cartográficos. Os dados cartográficos utilizados foram as curvas de nível do terreno equidistantes 1,5m entre linhas. O planejamento de plantio necessita de informações fiéis das curvas de nível.

Na etapa seguinte, o ortomosaico foi tratado em um software de SIG (Qgis 2.18), para recorte e reconhecimento da área de estudo. Nessa etapa, a área de estudo foi separada em classes para mensuração da quantidade de área em solo exposto e plantas de café. Para tal análise, procedeu-se as operações aritméticas com valores obtidos da banda do visível (RGB) baseado no índice de vegetação (IV) MPRI (Modified 181 Photochemical Reflectance Index) proposto por Yang et al. (2008) conforme descrito na (Eq. 1).

$$MPRI = \frac{(G - R)}{(G + R)} \quad eq (1)$$

Em que MPRI é o índice de reflexão fotoquímica modificada, decimal; G é o valor de refletância obtidas do espectro na região do verde, decimal; e R é o valor de refletância obtido do espectro na região do vermelho, decimal.

**RESULTADOS E DISCUSSÃO:** Na Tabela 2 estão apresentados os resultados referentes ao uso do solo na lavoura cafeeira em estudo (implantada sem o uso de imagens de ARP ou levantamentos topográficos) e uma simulação de planejamento com aplicação de ARP, para a otimização quanto à locação de carregadores.

TABELA 2. Aproveitamento de e uso do solo em hectares, obtidos por imagens aéreas e simulações de carregadores projetados. **Land use and utilization in hectares, obtained by aerial images and simulations of projected carriers.**

	Plantio Antigo		Simulação com ARP
	Talhão	Carreadores antigos	Carreadores Novos
área (ha)	16,84	1,87	0,24
Ocupação do solo (%)	100	11,1	1,4

Conforme pode ser visualizado na Tabela 2 o uso de dados oriundos de ARPs contribuem para melhorias no aproveitamento de áreas de plantio. Observa-se que os carregadores antigos ocupavam 11,1% da área de cultivo, o que influencia na redução expressiva da produção final do cafeeiro. Cafeeiros implantados em décadas passada são caracterizados por espaçamentos superiores e maiores quantidades de carregadores devido à baixa implementação de mecanização agrícola. Pesquisas de Matiello et al. (2010) identificaram que redução de espaçamentos aumentam a produtividade e melhoram o desenvolvimento da planta. Além disso, observaram que em lavouras implantadas a menos de 30 anos, tem ocorrido maior preocupação em relação à distribuição de plantas ao longo da linha, evidenciando as tendências de plantios em menores distâncias, com variações entre 0,5 e 1 m. A melhor ocupação de áreas de solo exposto, conforme visto nos valores de carregadores novos, também contribuem para redução de escoamento superficial contribuindo para melhor manutenção e fertilidade do solo (NAVARRO et al., 2021).

Procedimentos para obtenção de informações na agricultura são essenciais para acessibilidade concreta de técnicos e produtores. Na Figura 2 são apresentados os passos para obtenção dos dados essenciais para o planejamento de linhas de plantio na cafeicultura.






FIGURA 2. Procedimento para planejamento de linha de plantio de cafeeiros em declividades elevadas. a) Ortomosaico, b) Modelo digital de terreno (MDT), c) Curvas de nível e d) Linhas de plantio. **Procedure for planning a coffee plantation rows on high slopes. a) Orthomosaic, b) Digital Terrain Model (MDT), c) Land contour curves and d) Planting lines.**

Conforme pode ser visualizado na Figura 2, os procedimentos metodológicos podem seguir quatro importantes etapas: Ortomosaico, Modelo digital de terreno (MDT), Curvas de nível e Linhas de plantio. A adequação das linhas de plantio ocorre de acordo com a necessidade e as características do talhão, e devem ser consideradas principalmente o uso de mecanização e a inclinação do terreno. Essas podem ser características limitantes para ocupação do solo em algumas regiões (Santana et al., 2022). No planejamento do plantio de cafeeiro, variações abruptas são fatores que estimulam o produtor a incrementar o acesso secundário ao cultivo (Gimenes et al., 2017). Dessa forma, a aplicação das técnicas apresentadas na Figura 2 permite a identificação prévia de regiões inaptas ao plantio e oferece melhores possibilidades para construção de acessos.

**CONCLUSÃO:** A aplicação de produtos cartográficos obtidos por aeronaves remotamente pilotadas para o planejamento de linhas de plantio e otimização de uso do solo foi satisfatório.

A aplicação dos modelos digitais de elevação no planejamento otimizou o uso do solo em 10%, o que poderá contribuir para o aumento de produção de café nessa área em questão.

#### **AGRADECIMENTOS:**

Os autores agradecem à Embrapa Café – Consórcio Pesquisa Café pelo financiamento do projeto (nº 10.18.20.041.00.00), aos proprietários da Fazenda Bom Jardim, ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e a Universidade Federal de Lavras (UFLA).

#### **REFERÊNCIAS**

MATIELLO, J. B.; SANTINATO, R.; GARCIA, A. W. R.; ALMEIDA, S. R.; FERNANDES, D. R. Cultura de café no Brasil: manual de recomendações. Rio de Janeiro: **MAPA/Procafé**, 2010..

NAVARRO, R.; MARTELÓCIO, A. C.; SEVILHA, R.; BIDO, G., MANNIGEL, A. Manejo do solo para o sistema de cultivo do café no Brasil. **Enciclopédia biosfera**, v.18, n. 38, 2021.

SANTANA, L. S.; FERRAZ, G. A. E. S.; MARIN, D. B.; FARIA, R. D. O.; SANTANA, M. S.; ROSSI, G.; PALCHETTI, E. Digital Terrain Modelling by Remotely Piloted Aircraft: Optimization and Geometric Uncertainties in Precision Coffee Growing Projects. **Remote Sensing**, v. 14, n. 4, p. 911, 2022.

GIMENES, G.R.; OLIVEIRA, R.B.; SILVA, A.F.; REIS, L.C.; REIS, T.E.S. Mapping of slopes for the operation of agricultural harvesters in Bandeirantes Municipality (PR). **Semina Agraria**, v. 38, p. 97–107, 2017.

MOREIRA, P. C.; MOREIRA, G. C.; CASTRO, N. R.; SILVA, R. P. Produtividade e economia de fatores de produção na cafeicultura brasileira. **Revista de Política Agrícola**, v. 28, n. 2, p. 6, 2019.

SARA, C. E. D. A. B.; FERNANDES, A. M.; LIMA, A. P. A.; COSTA, L. T. D.; CUNHA, C. N. Competitividade da cafeicultura brasileira. **Revista de Política Agrícola**, v. 27, n. 3, p. 9-16, 2019.

FERRAZ, G. F. A.; SILVA, F. M.; CARVALHO ALVES, M.; LIMA BUENO, R.; COSTA, P. A. N. Geostatistical analysis of fruit yield and detachment force in coffee. **Precision Agriculture**, v. 13, n. 1, p. 76-89, 2012.

SANTANA, L. S.; SANTOS, L. M.; MACIEL, D. A.; BARATA, R. A. P.; REYNALDO, É. F.; ROSSI, G. Vegetative vigor of maize crop obtained through vegetation indexes in orbital and aerial sensors images. **Revista Brasileira de Engenharia de Biosistemas**, v.13, n.3, p. 195-206, 2019.

RUMPLER, M.; WENDEL, A.; BISCHOF, H. Probabilistic range image integration for DSM and true-orthophoto generation. **Springer**, p.533–544, 2013.

# DIFERENTES SENSORES EMBARCADOS EM VANT PARA PREDIÇÃO DA BIOMASSA DE PASTAGEM

Gabriela Maria Amaral Vallim Costa<sup>1</sup>; Jussara Oliveira Gervasio<sup>2</sup>; Samuel de Assis Silva<sup>3</sup>

<sup>1</sup>Estudante, Graduando - Centro de Ciências Agrárias e Engenharias, UFES-ES. gmavc2912@gmail.com / (22) 9 9782-4167; <sup>2</sup>Estudante, Graduado - Centro de Ciências Agrárias e Engenharias, UFES-ES;

<sup>3</sup>Engenheiro Agrônomo, Professor - Depto. Engenharia Rural, UFES-ES

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** O sensoriamento remoto permite inferir sobre o vigor vegetativo das gramíneas, contribuindo com um sistema nutricional de qualidade para o rebanho. Objetivou-se avaliar diferentes sensores embarcados em veículo aéreo não tripulado para a estimativa de biomassa do capim-tanzânia (*Panicum maximum* cv. Tanzânia). O desenvolvimento das plantas foi avaliado utilizando imagens digitais e medições de biomassa in loco. Para avaliação indireta da biomassa, o comportamento espectral das plantas foi avaliado utilizando imagens obtidas por dois diferentes sensores: sensor ótico RGB e sensor ótico multiespectral. Os índices de vegetação foram calculados para avaliar o vigor vegetativo. Os índices RGB da câmera multiespectral que apresentam maiores correlações e maiores concordâncias foram utilizados para serem correlacionados com os índices RGB da câmera digital e posteriormente, foram submetidos a regressão linear e regressão polinomial de segundo grau. Os índices de vegetação calculados a partir do sensor RGB descrevem o vigor vegetativo, porém, há perda de informação em relação aos índices calculados a partir da câmera multiespectral.

**PALAVRAS-CHAVE:** Imagens digitais; Índices de vegetação; Regressão

## DIFFERENT SENSORS EMBEDDED IN UAV FOR PREDICTION OF PASTURE BIOMASS

**ABSTRACT:** Remote sensing allows to infer about the vegetative vigor of the grasses, contributing to a quality nutritional system for the herd. The objective of this study was to evaluate different sensors embedded in an unmanned aerial vehicle for the estimation of tanzania grass biomass (*Panicum maximum* cv. Tanzânia). Plant development was evaluated using digital images and on-site biomass measurements. For indirect evaluation of biomass, the spectral behavior of the plants was evaluated using images obtained by two different sensors: RGB optical sensor and multispectral optical sensor. Vegetation indexes were calculated to evaluate vegetative vigor. The RGB indices of the multispectral camera with higher correlations and higher agreements were used to be correlated with the RGB indices of the digital camera and later, they were submitted to linear regression and second-degree polynomial regression. Vegetation indices calculated from the RGB sensor describe vegetative vigor, however, there is a loss of information in relation to the indexes calculated from the multispectral camera.

**KEYWORDS:** Linear correlation; Vegetation index; Multiple regression

**INTRODUÇÃO:** O sensoriamento remoto vem sendo difundido nos sistemas agrícolas por auxiliar de forma significativa nas avaliações das condições vegetativas, disponibilizando informações que podem proporcionar a melhora do sistema produtivo de uma área (MANABE et al., 2018). Nesse sentido e no caso específico das pastagens, o sensoriamento remoto fornece dados mais detalhados permitindo inferir, de forma indireta, sobre o vigor vegetativo das gramíneas contribuindo com um sistema nutricional de qualidade para o rebanho (VELOSO et al., 2020).

O uso de satélites no sensoriamento remoto fornece dados com rapidez e já vem sendo utilizado na agricultura nas últimas décadas, porém, há grandes limitações quanto a resolução espacial desses sensores, além da ocorrência de nuvens em determinadas épocas do ano (FORMAGGIO; SANCHES, 2017) o que, nessas condições, dificulta ou inviabiliza a sua utilização. A utilização do veículo aéreo não tripulado é uma alternativa viável em diversas áreas uma vez que, a depender do sensor embarcado, é capaz de coletar dados com alta precisão (NORASMA et al., 2019).

As câmeras digitais comuns, possibilitam estudos a respeito da vegetação, uma vez que fornecem imagens de alta qualidade (BARBOSA et al., 2016). As câmeras RGB (que captam as bandas do vermelho, verde e azul) são comumente usadas devido ao seu baixo custo e seu design compacto (LINHARES et al., 2013) mas em alguns casos, faz-se necessário o uso de sensores multiespectrais.

Sensores multiespectrais vêm sendo utilizados para fornecer dados precisos a respeito das culturas (KHANNA et al., 2017), pois eles captam os comprimentos de onda específicos permitindo por exemplo, estudos radiométricos. Um ponto a ser observado na utilização dessa tecnologia é a sua calibração radiométrica (POZO et al., 2014). As imagens necessitam de correção devido à grande incidência de energia eletromagnética sobre o objeto de estudos, logo, os parâmetros espaciais extrínsecos devem ser levados em consideração na hora da junção de imagens (POZO et al., 2014; KHANNA et al., 2017). Objetivou-se avaliar diferentes sensores embarcados em veículo aéreo não tripulado para a estimativa de biomassa do capim-tanzânia (*Panicum maximum* cv. Tanzânia).

## **MATERIAIS E MÉTODOS:**

O experimento foi conduzido em área plana cultivada com capim-tanzânia (*Panicum maximum* cv. Tanzânia), localizada no município de Alegre, região sul do estado do Espírito Santo, sob as coordenadas médias de 20°44'53" S e 41°29'10" W. A área estava em descanso, pronta para ser pastejada e não foi submetida a adubações. O clima da região é classificado como "Cwa", tropical quente-úmido, com inverno frio e seco, temperatura anual média de 23,1 °C e precipitação total anual média de 1341 mm (KÖPPEN e GEIGER, 1928).

Foi utilizado uma grade amostral contendo 10 pontos selecionados ao acaso, os quais foram georreferenciados utilizando um receptor GNSS geodésico, com correção pós-processada e precisão sub-centimétrica. O desenvolvimento das plantas foi avaliado utilizando imagens digitais obtidas com veículo aéreo não tripulado (VANT) e medições de biomassa in loco, ambas avaliações ocorreram no mesmo dia.

Para medições da biomassa in loco foram coletadas amostras nos pontos já selecionados. Foi utilizado um gabarito quadrado (1m x 1m) com 1m<sup>2</sup> de área, o qual foi lançado sobre cada ponto e a pastagem compreendida pelo gabarito foi coletada a 0,20 m do solo. A coleta foi realizada no verão, período compreendido por pancadas de chuvas. O material foi conduzido ao laboratório onde foi realizada a pesagem da massa fresca seguida de secagem em estufa de circulação forçada onde ficou a 65° C por 72 horas (RODRIGUES, 2010). Por fim, foi realizada a pesagem para obtenção da massa seca (em gramas) para a determinação da biomassa do *P. maximum* cv. Tanzânia.

Para avaliação indireta da biomassa, o comportamento espectral das plantas foi avaliado utilizando imagens obtidas por dois diferentes sensores: a) sensor ótico RGB CMOS equipado com lentes FOV 84° 8.8 mm/24 mm, que captura segmentos dos comprimentos de onda do espectro eletromagnético do visível: vermelho (R-red); verde (G -green), e; azul (B - blue) – para uso deste sensor todas as funções automáticas, passíveis de intervenção, foram desativadas e as que não permitiam a desativação foram configuradas para minimizar os pré-processamentos internos; b) sensor ótico multiespectral RedEdge MX que captura segmentos dos comprimentos de onda do espectro eletromagnético do visível (R, G e B), do RedEdge e do infravermelho próximo (NIR).

Os sensores foram embarcados em dois veículos aéreos não tripulados (VANT): o sensor RedEdge MX foi embarcado no Inspire 2 enquanto o sensor RGB é item de fábrica no Phantom 4 Pro, ambos fabricados pela DJI. Para os mapeamentos foram utilizados pontos de controle e de verificação (fotointerpretáveis). A materialização desses pontos foi realizada utilizando um receptor GNSS geodésico de precisão sub-centimétrica. Calibrações geométricas e radiométricas foram realizadas. As imagens calibradas foram processadas para obtenção dos mosaicos de ortofotos (ortomosaicos) utilizando o software livre OpenDroneMap (Drone Mapping Software).

De posse dos ortomosaicos e utilizando o software QGIS (versão 3.16.10) foi realizado um recorte da imagem, deixando apenas a feição de interesse (área de cultivo da pastagem). Para avaliar a distribuição espacial e relacionar os produtos obtidos com diferentes sensores, foi construída, a partir de uma camada vetorial de pontos, uma malha amostral contendo 51 pontos amostrais, distribuídos aleatoriamente na área onde, para cada

um dos 51 pontos amostrais construiu-se um buffer com diâmetro de 1 metro, visando ampliar a área de influência de cada ponto. Após concluída essa etapa, a camada vetorial contendo os 51 pontos (cada ponto com área de 0,7854m) foram utilizados para a extração dos comprimentos de onda de cada banda espectral dos sensores MX (RedEdge) e P4 (sensor RGB do Phantom 4 Pro).

A partir dos números digitais e valores de reflectância gerados nas imagens obtidas com os dois sensores (MX e P4) realizou-se a análise qualitativa dos índices de vegetação estudados. Foram calculados seis índices de vegetação (Tabela 1), comumente utilizados, com base nos valores das bandas espectrais obtidos pela câmera RedEdge MX. Como a câmera RGB não capta valores de bandas multiespectrais logo, os índices Índice de Vegetação por Diferença Normalizada (Normalized Difference Vegetation Index – NDVI) e o Índice de Borda Vermelha de Diferença Normalizada (Normalized Difference Red Edge Index - NDRE) não foram calculados com os valores extraídos do sensor embarcado no P4.

TABELA 1. Índices de vegetação utilizados para a estimativa de biomassa de pastagem. **Vegetation indexes used to estimate pasture biomass.**

Índices de vegetação	Fórmula
Índice de Vegetação por Diferença Normalizada (Normalized Difference Vegetation Index – NDVI)	$\frac{NIR - R}{NIR + R}$ Eq. (4)
Índice de Borda Vermelha de Diferença Normalizada (Normalized Difference Red Edge Index - NDRE)	$\frac{NIR - REEDGE}{NIR + REEDGE}$ Eq. (5)
Índice verde/vermelho por diferença normalizada (Normalized Green Red Difference Index - NGRDI)	$\frac{G - R}{G + R}$ Eq. (6)
Índice de resistência atmosférica visível (Visible Atmospherically Resistant Index - VARI)	$\frac{G - R}{G + R - B}$ Eq. (7)
Índice de vermelhidão (Redness Index - RI)	$\frac{R - G}{R + G}$ Eq. (8)
Análise de imagem ao nível do solo (Ground Level Image Analysis - GLI)	$\frac{(G - R) + (G - B)}{G + R + G + B}$ Eq. (9)

Em que R, G e B são as bandas green (verde), red (vermelho) e blue (azul), respectivamente. NIR é a energia refletida no infravermelho próximo e RedEdge é a energia refletida no intervalo de onda “rededge” do espectro eletromagnético.

Inicialmente, apenas os índices de vegetação para os produtos da MX foram correlacionados, correlacionando-se índices multiespectrais com índices RGB. Para a seleção dos melhores produtos, os valores dos índices foram calculados para cada um dos 51 pontos amostrais e, posteriormente, correlacionados entre si utilizando o coeficiente de correlação linear de Pearson.

O NDVI e o NDRE foram determinados para avaliar de forma quantitativa e qualitativa o vigor vegetativo das plantas e subsidiar modelos para realização da estimativa de biomassa. Para avaliar também a distribuição espacial dos valores dos índices, os valores calculados a partir dos 51 pontos foram agrupados utilizando o algoritmo k-means. Foram construídas três grupos para todos os índices, os quais foram contrastados para avaliar a concordância entre agrupamentos a partir do índice Kappa. Na estatística Kappa, o coeficiente Kappa indica a superioridade da reclassificação sobre uma classificação ao acaso onde são considerados os seguintes intervalos: Kappa <0 - concordância péssima e não significativa; Kappa entre 0 e 0,20 - a concordância é significativa, mas baixa; Kappa entre 0,21 e 0,40 - significativo e razoável; Kappa > 0,40 - concordância significativa e boa (CONGALTON; MEAD, 1986).

A seleção dos melhores índices RGB se deu a partir dos maiores valores de correlação significativa e maiores concordâncias, considerando para esse último a classificação proposta por COHEN (1960).

Os índices, calculados para a imagem do sensor MX e a partir de bandas do visível (RGB), que apresentaram maiores correlações e maiores concordâncias com os índices multiespectrais foram utilizados como referências para a escolha dos equivalentes calculados para a imagem do sensor P4 (RGB CMOS).

Para a imagem, produto do sensor P4, foram extraídos os valores de cada banda para os 51 pontos amostrais, sendo posteriormente calculado, para cada ponto, os mesmos índices de vegetação descritos na Tabela 1 e que utilizam apenas as bandas do visível. Após esse cálculo, os resultados foram correlacionados (correlação linear de Pearson) com os equivalentes determinados a partir do sensor MX.

Para a predição de biomassa da pastagem foram utilizados: a) os índices multiespectrais (NDVI e NDRE); b) os índices RGB, obtidos a partir da imagem gerada pelo sensor MX, que apresentaram melhores desempenhos nas análises de correlação e de concordância com os multiespectrais, e; c) os RGB, obtidos a partir da imagem gerada pelo sensor P4, que apresentaram melhor desempenho nas análises de correlação com os equivalentes calculados a partir da imagem do sensor MX.

Para efeito de predição foram utilizados modelos de regressão linear múltipla e regressão polinomial. Como variável dependente foram considerados os valores de biomassa medida *in loco* e como variáveis independentes foram considerados os valores dos índices de vegetação mensurados nos mesmos 10 pontos amostrais utilizados para coleta da forragem. As equações de regressão foram calculadas conforme equações:

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k \quad \text{Eq. (10)}$$

$$Y = \beta_0 + \beta_1 x_1 + [\beta_2 x_1]^2 + \beta_3 x_2 + [\beta_4 x_2]^2 + \dots + \beta_k x_k + [\beta_{(k+1)} x_k]^2$$

Em que:  $Y$  = variável dependente;  $\beta_0$  = valores do intercepto;  $\beta_{i(i=1...k)}$  = valores dos coeficientes de regressão parciais, e;  $x_{i(i=1...k)}$  e  $x_{i^2(i=1...k)}$  = as variáveis independentes.

Foram utilizados modelos de regressão linear e polinomial e seus termos quadráticos para predição da biomassa de pastagem a partir dos índices de vegetação selecionados. Todos os dados foram processados em ambiente estatístico.

No intuito de avaliar a eficiência dos modelos utilizados, foram calculados os indicadores estatísticos de eficiência: a) erro médio absoluto (MAE), e; b) erro relativo (ER %). O MAE é dado pela seguinte equação:

$$MAE = \left(\frac{1}{n}\right) \sum_{i=1}^n |O_i - E_i| \quad \text{Eq. (11)}$$

em que:  $MAE$  é o erro médio absoluto,  $O_i$  e  $E_i$ , são respectivamente, os valores preditos e observados e  $n$  corresponde ao número de dados trabalhados.

O ER é dado pela equação abaixo:


$$ER = \left(\frac{100}{n}\right) \sum_{i=1}^n \left| \frac{(O_i - E_i)}{O_i} \right| \quad \text{Eq. (12)}$$

em que:  $ER$  é o erro relativo médio (%),  $O_i$  e  $E_i$ , são, respectivamente, os valores preditos e observados e  $n$  corresponde ao número de dados trabalhados.

**RESULTADOS E DISCUSSÃO:** A partir dos procedimentos metodológicos listados anteriormente são apresentados abaixo os resultados da distribuição espacial dos índices de vegetação (sendo os multiespectrais calculados a partir das imagens da RedEdge MX e os RGB calculados tanto a partir da RedEdge MX quanto pelo sensor CMOS embarcado no P4). São apresentados também as estatísticas de correlação e concordância para a seleção dos índices a serem utilizados na predição da biomassa. Os valores dos respectivos índices selecionados, os modelos de regressão para a predição da massa de biomassa da pastagem e avaliação qualitativa das predições são igualmente apresentados neste item.

A distribuição espacial dos índices multiespectrais é apresentada na Figura 1. Os valores de NDVI (Figura 1A) e NDRE (Figura 1B) variaram ao longo da extensão da área, com maior amplitude para o NDVI apesar deste

ter ficado concentrado no intervalo de 0,85 a 1. No caso do NDRE, a amplitude máxima foi menor, porém a maior parte das plantas cultivadas na área apresentaram maiores diferenças entre si, com valores variando entre 0,30 a 0,50.



A B

FIGURA 1. Mapas temáticos dos índices de vegetação NDVI (A) e NDRE (B) calculados a partir das imagens obtidas com sensor multiespectral embarcado em VANT. **Thematic maps of the NDVI (A) and NDRE (B) vegetation index calculated from the images obtained with multispectral sensor embedded in UAV.**

Os maiores valores de NDVI e NDRE foram observados na porção centro-norte da área indicando maior vigor vegetativo. Apesar do NDVI ter apresentado esse comportamento valores altos desse índice (superiores a 0,88) podem indicar saturação assintótica, condição na qual o índice perde a capacidade de detectar pequenas variações (RISSO et al., 2012). Em trabalho com a cultura da soja, RISSO et al. (2012) identificaram que essa saturação é recorrente com desenvolvimento avançado da cultura acarretando problemas espectrais entre as variações das classes.

O NDRE (Figura 1b) é um índice extremamente eficaz para o monitoramento do teor de clorofila uma vez que, utiliza em seu cálculo matemático o comprimento de onda referente ao rededge que, possui maior capacidade de penetração nas camadas das células foliares quando comparada aos comprimentos de onda vermelho e azul (BOIARSKIII; HASEGAWA; 2019). LISBOA (2020) ao utilizar diferentes índices de vegetação para predição de massa de forragem em pastos de *Brachiaria decumbens* encontrou no NDRE maiores correlações entre as variáveis estudadas.

Os valores dos índices, extraídos para os 51 pontos distribuídos aleatoriamente na área, foram correlacionados entre si. O resultado da análise de correlação de Pearson é apresentado na Tabela 2.

TABELA 2. Correlação linear de Spearman entre os índices RGB e os índices NDVI e NDRE calculados a partir das imagens obtidas com sensor multiespectral embarcado em VANT. **Spearman's linear correlation between the RGB indices and the NDVI and NDRE index calculated from the images obtained with a multispectral sensor embedded in UAV.**

Índices	Coeficiente de Correlação	
	NDVI	NDRE
NGRDI	0,923	-0.547

VARI	0.925	0.545
RI	-0.926	-0.547
GLI	0.927	0.543

O NVDI apresentou alta correlação positiva com os índices, exceto com o RI onde apresentou alta correlação negativa (Tabela 2). Em relação ao NDRE, quando correlacionado com o VARI e o GLI, este apresentou correlação positiva, já com o NGRDI e o RI apresentou correlação negativa. Ao observar os resultados expressos na Tabela 2, observa-se padrões no comportamento de distribuição amostral entre os diferentes índices. As análises de correlação entre as variáveis foram propostas para avaliar o grau de similaridade entre os índices, quanto mais perto de 1 maior é a associação entre eles (PARANHOS et al., 2014). Correlações menores que zero indicam que enquanto uma variável diminui a outra aumenta (PARANHOS et al., 2014).

Os resultados obtidos a partir dos índices foram agrupados e submetidos a estatística Kappa (COHEN, 1960) (Tabela 3) no intuito de avaliar o nível de concordância entre os dois conjuntos.

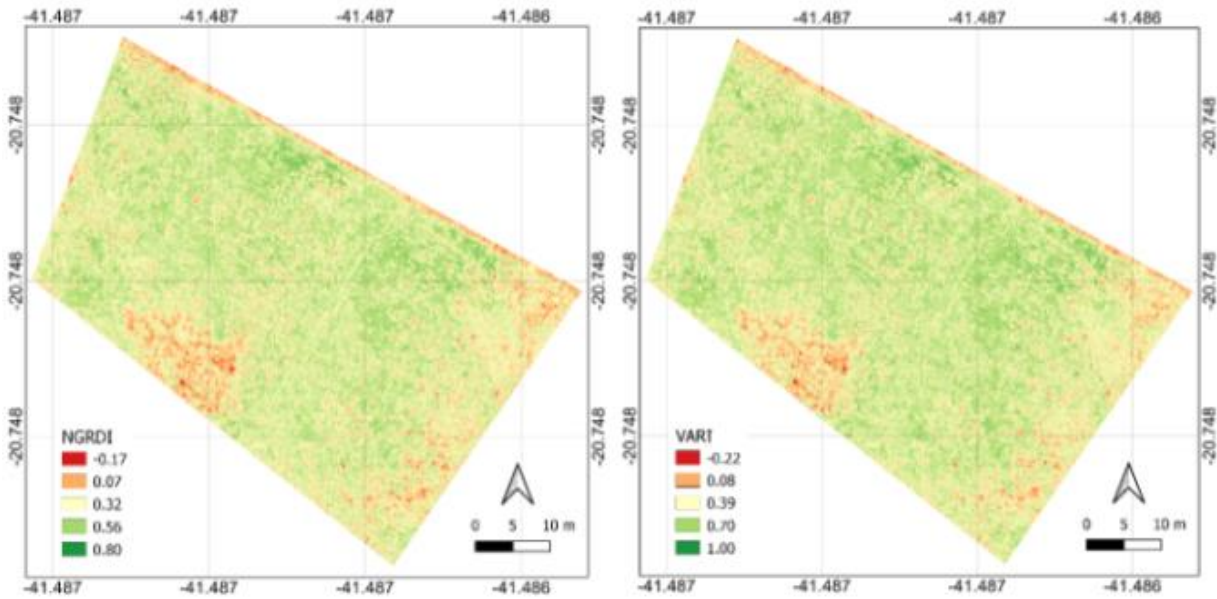
Os índices apresentaram coeficiente Kappa de péssimo e não significativo a significativo e razoável conforme escala de validação desenvolvida por CONGALTON E MEAD (1991). O índice NGRDI apresentou concordância significativa, porém baixa com o NDVI enquanto que o VARI apresentou concordância significativa e razoável com NDVI e NDRE. Os demais índices RGB não apresentaram concordância significativa com os multiespectrais. GONÇALVES et al. (2017) ao avaliar a resposta espectral em uma área de gramado encontrou alta correlação do NGRDI com o NDVI. Resultados diferentes foram observados por ABRAHÃO et al. (2009) onde, ao estudar a correlação de índices de vegetação com leituras de clorofila e massa seca em *P. maximum* Jacq., cv. Tanzânia não encontrou correlação significativa com o índice.

Tabela 3. Índice Kappa entre os agrupamentos dos índices RGB e dos índices NDVI e NDRE calculados a partir das imagens obtidas com sensor multiespectral embarcado em VANT. **Kappa index between the clusters of rgb indices and NDVI indices and NDRE calculated from the images obtained with multiespectral sensor embedded in UAV.**

Estatística Kappa				
Variáveis	NDVI		NDRE	
	Kappa	Variância	Kappa	Variância
NGRDI	0.152	0.000033	0.012	0.000036
VARI	0.212	0.000036	0.262	0.000037
RI	-0.320	0.000022	-0.099	0.000034
GLI	-0.060	0.000023	-0.112	0.000034

Os índices de vegetação NGRDI e VARI foram os que apresentaram maior concordância e foram selecionadas para serem correlacionados com os equivalentes obtidos a partir do sensor do Phantom 4 Pro.






A B

FIGURA 2. Mapas temáticos dos índices de vegetação NGRDI (A) e VARI (B) calculados a partir das imagens obtidas com sensor multiespectral embarcado em VANT. **Thematic maps of NGRDI (A) and VARI (B) vegetation index calculated from the images obtained with multispectral sensor embedded in UAV.**

Os valores dos índices NGRDI (Figura 2A) e VARI (Figura 2B) variaram ao longo da extensão da área, com maior amplitude para o NGRDI, este, apresentou maior concentração de valores entre 0,56 a 0,80 e o VARI apresentou valores variação de 0,70 a 1,00.




A B

FIGURA 3. Mapas temáticos dos índices de vegetação NGRDI (A) e VARI (B) calculados a partir das imagens obtidas com sensor RGB embarcado em VANT. **Thematic maps of NGRDI (A) and VARI (B) vegetation index calculated from the images obtained with RGB sensor embedded in UAV.**

Na Figura 3, é apresentada a distribuição espacial dos índices RGB do sensor P4. Os índices NGRDI (Figura 3A) e VARI (Figura 3B) informaram pontos extremamente baixos de vigor vegetativo ao longo da área, com valores concentrados entre 0,56 a 0,80 para o NGRDI e 0,70 a 1,00 para o VARI, na região centro-norte da área.

Analisando, comparativamente, os mapas dos índices NGRDI e VARI e do sensor MX e os equivalentes do sensor P4, observa-se que para o primeiro os valores absolutos foram superiores ao segundo. Essas diferenças entre sensores eram esperadas devido às diferenças nos sensores, quer seja no objetivo, quer seja no seguimento de leitura dentro do mesmo comprimento de onda.



(A) (B)

FIGURA 4. Correlação entre os índices NGRDI (A) e VARI (B) obtidos a partir das imagens do sensor multiespectral (sufixo \_MX) e das imagens do sensor RGB (sufixo \_P4). **Correlation between NGRDI (A) and VARI (B) index obtained from multiespectral sensor images (suffix \_MX) and RGB sensor images (suffix \_P4).**

Nos gráficos de correlação entre os índices, observa-se que ambos os modelos apresentam coeficientes de determinação ( $R^2$ ) significativos, o que indica que há semelhanças na resposta dos índices determinados pelos diferentes sensores. A partir desses resultados afirma-se que, apesar da perda de informação (ausência de um  $R^2$  igual a 1), os valores do NGRDI (Figura 4A) e VARI (Figura 4B) calculados a partir do sensor CMOS é capaz de descrever o comportamento da vegetação com semelhança ao realizado pelos mesmos índices calculados a partir dos produtos da RedEdge MX.

Tendo em vista que os índices de vegetação que utilizam bandas multiespectrais são mais eficazes para prever biomassa (FU et al. 2020), e que o NGRDI e o VARI apresentaram correlação satisfatória e  $R^2$  significativos, estes foram selecionados para serem utilizados na previsão de biomassa. Foram utilizados como algoritmos preditores a regressão linear múltipla e a regressão polinomial de grau dois. Visto que o modelo linear é um teste clássico, ele foi escolhido para ser utilizado como modelo de regressão. Já o modelo de regressão polinomial (grau 2), usual em estudos envolvendo aprendizado de máquinas (machine learning), foi escolhido devido ao fato de perder menos informações quando comparado ao modelo linear. Os resultados são apresentados na Tabela 4.

Tabela 4. Modelos de regressão linear e polinomial para previsão da biomassa de pastagem a partir dos índices de vegetação de diferentes sensores. **Linear and polynomial regression models for prediction of pasture biomass from the vegetation index of different sensors.**

Variável	Equação	$R^2$ (%)
Multiespectral		
NDVI	$Y = -590.73924 + 970.7049 * NDVI$	22.57
NDVI <sup>2</sup>	$Y = 24112.2926 - 59544.5849 * NDVI + 37001.0216 * NDVI^2$	41.82
NDRE	$Y = -193.2366 + 1141.9161 * NDRE$	41.85

NDRE <sup>2</sup>	$Y = 699.3911 - 4009.7275 * NDRE + 7344.3793 * NDR^2$	43.13
(NDVI_NDRE)	$Y = 573.0303 - 1407.5575 * NDVI + 2251.4208 * NDRE$	49.79
(NDVI_NDRE) <sup>2</sup>	$Y = 33311.6511 - 88871.7 * NDVI + 53114.5699 * NDVI^2 + 20320.2041 * NDRE - 25117.2022 * NDRE^2$	75.72
RGB_MX		
NGRDI	$Y = 16.3871 + 481.3773 * NGRDI$	9.75
NGRDI <sup>2</sup>	$Y = 2439.4490 - 11887.5706 * NGRDI + 15587.3987 * NGRDI^2$	25.92
VARI	$Y = 4.3795 + 390.0388 * VARI$	10.55
VARI <sup>2</sup>	$Y = 2175.8453 - 8030.2862 * VARI + 8064.9330 * VARI^2$	23.27
(NGRDI_VARI)	$Y = -18.6579 - 2971.4639 * NGRDI + 2697.6925 * VARI$	12.78
(NGRDI_VARI) <sup>2</sup>	$Y = 1806 - 147381.7423 * NGRDI + 181018.4480 * NGRDI^2 + 105390.3053 * VARI - 97863.4436 * VARI^2$	44.61
RGB_P4		
NGRDI	$Y = 73.4306 + 571.6064 * NGRDI$	17.96
NGRDI <sup>2</sup>	$Y = 195.8283 - 549.9436 * NGRDI + 2447.1719 * NGRDI^2$	18.67
VARI	$Y = 65.2508 + 472.8850 * VARI$	19.16
VARI <sup>2</sup>	$Y = 158.5995 - 189.3638 * VARI + 1122.0620 * VARI^2$	19.52
(NGRD_VARI)	$Y = 35.8151 - 4776.2607 * NGRDI + 4291.2719 * VARI$	23.81
(NGRDI_VARI) <sup>2</sup>	$Y = -166.2961 - 34148.9425 * NGRDI + 58983.8704 * NGRDI^2 + 28439.7384 * VARI - 37772.0135 * VARI^2$	30.77

<sup>2</sup> – modelo polinomial.

Ao avaliarmos os modelos dos índices multiespectrais evidencia-se que a variável NDVI apresentou menor valor de R<sup>2</sup> enquanto (NDVI\_NDRE)<sup>2</sup> apresentou maior valor de R<sup>2</sup>. Os dois modelos, polinomial e linear, apresentaram R<sup>2</sup> semelhantes para as os índices NDRE e NDRE<sup>2</sup>.

Em relação aos índices RGB da câmera MX, os modelos lineares e polinomiais apresentaram R<sup>2</sup> bem distintos onde, os modelos polinomiais apresentaram maior R<sup>2</sup> para todos os índices. Para os índices RGB\_P4, tanto os modelos lineares quanto os polinomiais apresentaram R<sup>2</sup> semelhante, com exceção das variáveis (NGRD\_VARI) e (NGRD\_VARI)<sup>2</sup>.

Em relação aos três grupos, os modelos dos índices multiespectrais foram os que apresentaram maiores R<sup>2</sup>. O R<sup>2</sup> mostra o quanto a variação da variável dependente pode ser explicada pelo modelo e, conseqüentemente, pelas variáveis independentes onde, quanto maior o valor de R<sup>2</sup> melhor o seu ajuste (MACHADO et al., 2002).

Para todas as equações o coeficiente de determinação múltipla foi maior para os modelos polinomiais. Ante a esse fato, foram utilizados para a predição de biomassa de pastagem os modelos polinomiais com maior valor de R<sup>2</sup>, determinados para cada tipo de banda (ou combinação destas) e sensor, a saber: a) modelo polinomial para a combinação (NDVI\_NDRE)<sup>2</sup> (R<sup>2</sup> de 75,72%) (multiespec.); b) modelo polinomial para a combinação (NGRDI\_VARI)<sup>2</sup> – R<sup>2</sup> de 44,61% (RGB\_MX), e; c) modelo polinomial para a combinação (NGRDI\_VARI)<sup>2</sup> – R<sup>2</sup> de 30,77% (RGB\_P4).

A ordem polinomial tem um efeito sobre o desempenho da regressão ao avaliar de forma efetiva as relações entre as variáveis dos dados de entrada (PANG et al., 2022). As regressões polinomiais vêm sendo utilizadas pois, atingem resultados satisfatórios como os encontrados no trabalho de PANG et al. (2022).

Na Tabela 5 são apresentados os resultados dos indicadores de eficiência dos modelos de predição de biomassa.

Tabela 5. Erro médio absoluto (MAE) e erro relativo (ER) da predição de biomassa de pastagem com diferentes modelos de regressão. **Absolute mean error (MAE) and relative error (RE) of pasture biomass prediction with diferente regression models.**

Índices	MAE (g)	ER (%)
NDVI_NDRE	28.98	16.42
RGB_MX	31.17	24.11
RGB_P4	47.77	33.00

Visto que quanto menor o valor do MAE, maior é a precisão da estimativa da variável, o modelo RGB\_P4 foi o que apresentou o menor desempenho para predição da biomassa. Apesar disso, quando comparado com o desvio padrão da biomassa observada (desvio padrão = 71,00 g) o modelo RGB\_P4 possui baixo valor de MAE, podendo ser utilizado para a predição de biomassa, assim como os outros dois modelos. Os modelos polinomiais (Tabela 4) apresentaram os maiores valores de coeficiente de determinação múltipla.

O erro relativo apresentou variação considerável entre os modelos estudados, a variação do erro foi de 16,42 a 33,00%. O índice multiespectral (ER = 16,24%) apresentou menor erro relativo, seguindo para o RGB\_MX (ER = 24,11%) e para o RGB\_P4 (ER = 33%) que, apresentou maior magnitude do erro quando comparado a outras duas variáveis estudadas. Os valores dos erros relativos foram baixos afirmando a possibilidade de utilização dos modelos para a predição da biomassa. Esse estudo condiz com os de Oliveira et al. (2014) que, ao utilizarem sensoriamento remoto para avaliação de evapotranspiração real diária obtiveram erro relativo variando de 0,0 a 30,00% com nível de precisão satisfatório.

**CONCLUSÃO:** Os índices de vegetação NGRDI e VARI calculados a partir do sensor RGB embarcado no Phantom 4 Pro são capazes de descrever o comportamento da vegetação com semelhança ao realizado pelos mesmos índices calculados a partir dos produtos da RedEdge MX.

O NDVI\_NDRE apresenta menor perda de informação com menores valores de erro médio absoluto (28,98 g) e erro relativo (16,42 %), ainda assim, é possível utilizar índices de vegetação calculados a partir de bandas do visível para a predição de biomassa de pastagens cultivadas. Ao se utilizar índices RGB para a predição de biomassa, o sensor CMOS embarcado no Phantom 4 pode ser utilizado em alternativa aos mesmos índices calculados a partir da RedEdge MX

## REFERÊNCIAS

ABRAHÃO, S. A.; PINTO, F. D. A. D. C.; QUEIROZ, D. M. D.; SANTOS, N. T.; GLERIANI, J. M.; ALVES, E. A. Índices de vegetação de base espectral para discriminar doses de nitrogênio em capim-tanzânia. **Revista Brasileira de Zootecnia**, V. 38, N. 9, P. 1637-1644, 2009.

BARBOSA, J. Z; CONSALTER, R.; PAULETTI, V; MOTTA, A. C. V. Uso de imagens digitais obtidas com câmeras para analisar plantas. **Revista de Ciências Agrárias**, V. 39, N. 1, P. 15-24, 2016.

BOIARSKII, B.; HASEGAWA, H. Comparison of ndvi and ndre indices to detect differences in vegetation and chlorophyll content. **Journal of Mechanics of Continua and Mathematical Sciences**, V. 4, P. 20-29, 2019.

- COHEN, J. A coefficient of agreement for nominal scales. **Educational and psychological measurement**, 20, 37-46, 1960.
- CONGALTON, R. G.; MEAD, R. A. A review of three discrete multivariate analysis techniques used in assessing the accuracy of remotely sensed data from error matrices. **IEEE Transactions on Geoscience and Remote Sensing**, n. 1, p. 169-174, 1986.
- FORMAGGIO, A. R.; SANCHES, I. D. Sensoriamento remoto em agricultura. **Oficina de Textos**, 2017
- FU, Z.; JIANG, J.; GAO, Y.; KRIENKE, B.; WANG, M.; ZHONG, K.; CAO, Q.; TIAN, Y.; ZHU, Y.; CAO, W.; LIU, X. Monitoring wheat growth and yield estimate based on unmanned aerial vehicle with multiple rotors. **Remote Sensing**, V.12 N.3:508, 2020.
- GONÇALVES, L.M; BARBOSA, B.D.S; MACIEL, D.T; SANTOS, H.F.D; variabilidade espacial e temporal do índice vegetação mPRI aplicado às imagens de grama são carlos obtidas por aeronave remotamente pilotada. **Revista Brasileira de Engenharia de Biosistemas**, V. 11, N. 4, P. 340-349, 2017.
- KHANNA, R.; SA, I.; NIETO, J.; SIEGWART, R. On field radiometric calibration for multispectral cameras. Proceedings - **Ieee International Conference On Robotics And Automation**, P. 6503–6509, 2017.
- KÖPPEN, W.; GEIGER, R. Klimate der erde. Gotha: **Verlag Justus Perthes**. 1928.
- LINHARES, M. M. A.; ROCHA, N. C. C.; AMARAL, B. A. S. Análise do índice mPRI como indicador vegetativo através da correlação do mesmo com o índice NDVI. **Simpósio Brasileiro De Sensoriamento Remoto**, V. 16, P. 8254-8260, 2017.
- LISBOA, A. M. Sensoriamento remoto na avaliação de pasto de brachiaria decumbens. 2020.
- MACHADO, S. D. A.; CONCEIÇÃO, M. B.; FIGUEIREDO, D. J. D. Modelagem do volume individual para diferentes idades e regimes de desbaste em plantações de pinus oocarpa. **Recen-Revista Ciências Exatas e Naturais**, V. 4, N. 2, P. 185-197, 2002.
- MANABE, V.; MELO, M.; ROCHA, J. Framework for mapping integrated crop-livestock systems in Mato Grosso, Brazil. **Remote Sensing**, V. 10, N. 9, P. 1322, 21 AGO. 2018.
- NORASMA, C. Y. N.; FADZILAH, M. A.; ROSLIN, N. A.; ZANARIAH, Z. W. N.; TARMIDI, Z.; CANDRA, F.S. unmanned aerial vehicle applications in agriculture. Iop Conference Series: **Materials Science and Engineering**, V. 506, N. 1, 2019.
- OLIVEIRA, L. M. D.; MONTENEGRO, S. M.; SILVA, B.B.D.; ANTONINO, A.C.; DE MOURA, A.E. Evapotranspiração real em bacia hidrográfica do nordeste brasileiro por meio do sebal e produtos modis. **Revista Brasileira de Engenharia Agrícola e Ambiental**, V. 18, P. 1039-1046, 2014.
- PANG, Y.; SHI, M.; ZHANG, L.; SONG, X.; SUN, W. PR-FCM: a polynomial regression-based fuzzy c-means algorithm for attribute-associated data. **Information Sciences**, V. 585, P. 209-231, 2022
- PARANHOS, R.; FIGUEIREDO, D. B.; ROCHA, E. C.; JÚNIOR, D. S. J. A.; NEVES, J. A. B.; SANTOS, M. L. W. D. **Desvendando os mistérios do coeficiente de correlação de Spearman: o retorno**. Leviathan (SÃO PAULO), N. 8, P. 66-95, 2014.
- POZO, S. D.; RODRÍGUEZ-GONZÁLVEZ, P.; HERNÁNDEZ-LÓPEZ, D.; FELIPE-GARCÍA, B. Vicarious radiometric calibration of a multispectral camera on board an unmanned aerial system. **Remote Sensing**, V. 6, N. 3, P. 1918-1937, 2014.
- RISSO, J., RIZZI, R., RUDORFF, B. F. T., ADAMI, M., SHIMABUKURO, Y. E., FORMAGGIO, A. R., & EPIPHANIO, R. D. V. Índices de vegetação modis aplicados na discriminação de áreas de soja. **Pesquisa Agropecuária Brasileira**, V. 47, P. 1317-1326, 2012.

RODRIGUES, R. C. Métodos de análises bromatológicas de alimentos: métodos físicos químicos e bromatológicos. **Documentos**, V. 306, P. 26-27. 2010.

VELOSO, G. A.; SILVA, J.R.; FERREIRA, M. E.; JÚNIOR, L. G. F. Biomassa seca estimada em áreas de pastagens com dados de sensoriamento remoto: estudo de caso na bacia hidrográfica do rio vermelho - goiás. **Sociedade e Território**, V. 32, N. 2, P. 150-171, 28 FEV. 2021.

# **CORRELAÇÃO ENTRE IAF E NDVI DE CULTIVARES CAFEIEIRAS RECÉM TRANSPLANTADAS COM IMAGENS AÉREAS OBTIDAS POR AERONAVE REMOTAMENTE PILOTADA**

**Lucas Santos Santana<sup>1</sup>; Sabrina Aparecida Teodoro<sup>5</sup>; Nicole Lopes Bento<sup>2</sup>; Gabriel Araújo e Silva Ferraz<sup>3</sup>; Pedro Henrique de Oliveira Estima<sup>4</sup>**

<sup>1</sup>Eng° Agrônomo , Doutorando em Engenharia Agrícola - Escola de Engenharia , Universidade Federal de Lavras (UFLA) Caixa Postal 3037 ? 37200-000 ? Lavras, MG . lucas.unemat@hotmail.com / (35) 9 9897-3964; <sup>2</sup>Eng° Ambiental , Doutorando em Engenharia Agrícola - Escola de Engenharia , Universidade Federal de Lavras (UFLA) Caixa Postal 3037 ? 37200-000 ? Lavras, MG ; <sup>3</sup>Eng° Agrícola , Professor - Escola de Engenharia , Universidade Federal de Lavras (UFLA) Caixa Postal 3037 ? 37200-000 ? Lavras, MG ; <sup>4</sup>Eng° Agrícola , Estudante - Escola de Engenharia , Universidade Federal de Lavras (UFLA) Caixa Postal 3037 ? 37200-000 ? Lavras, MG ; <sup>5</sup>Eng° Agrícola , Estudante - Escola de Engenharia , Universidade Federal de Lavras (UFLA) Caixa Postal 3037 ? 37200-000 ? Lavras, MG

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** A aplicação do sensoriamento remoto na cafeicultura estabelece um enorme avanço no levantamento de dados, no qual contribui para aprimorar as práticas de manejo e conservação da cultura. Dessa forma, o objetivo desse trabalho foi correlacionar dados de Índice de Área Foliar (IAF) com dados de Índice de Vegetação por Diferença Normalizada (NDVI) de imagens aéreas obtidas por Aeronave Remotamente Pilotada (Remotely Piloted Aircraft- RPA) de duas diferentes cultivares cafeeiras. Utilizou-se parâmetros do campo como: altura de planta (m) e diâmetro da copa (m) de vinte amostras de plantas cafeeiras. As cultivares estudadas foram Catucaí (2SL) e Bourbon (IACJ10). As imagens coletadas com RPA foram processadas para a obtenção de dados do NDVI. Foram correlacionados os dados do IAF com os dados de NDVI em ambiente de planilha eletrônica com obtenção dos coeficientes de correlação de Pearson (R), coeficiente de determinação (R<sup>2</sup>) e equação para as regressões do tipo linear, exponencial, log e potência. Observou-se que, para a cultivar Catucaí, o modelo potência apresentou o melhor ajuste com maior coeficiente de determinação R<sup>2</sup> de 0,7055, e para cultivar Bourbon, o modelo linear apresentou o melhor ajuste maior coeficiente de determinação, com R<sup>2</sup> de 0,6420. Com isso, conclui-se que por intermédio dos dados de NDVI foi possível obter o IAF do cafeeiro. Dessa forma, o NDVI pode ser utilizado para estimar o IAF.

**PALAVRAS-CHAVE:** Cafeicultura de Precisão; Sensoriamento Remoto; UAV

## **CORRELATION BETWEEN LAI AND NDVI OF RECENTLY TRANSPLANTED COFFEE CULTIVARS WITH AERIAL IMAGES OBTAINED BY REMOTELY PILOTED AIRCRAFT**

**ABSTRACT:** Remote sensing application in coffee farming establishes a huge advance in data collection, which it tributes to improving management and conservation practices. Thus, the objective of this work was to correlate Leaf Area Index (LAI) data with Normalized Difference Vegetation Index (NDVI) data from aerial images obtained by Remotely Piloted Aircraft (RPA) of two different coffee cultivars. Field parameters such: as plant height (m) and crown diameter (m) of twenty samples of coffee plants were used. The cultivars studied were Catucaí (2SL) and Bourbon (IACJ10). The images collected with RPA were processed to obtain NDVI data. The LAI data were correlated with the NDVI data in a spreadsheet environment, obtaining Pearson's correlation coefficients (R), coefficient of determination (R<sup>2</sup>), and equation for linear, exponential, log, and power regressions. It was observed that for the cultivar Catucaí, the potency model presented the best fit with the highest coefficient of determination R<sup>2</sup> of 0.7055, and for the cultivar Bourbon, the linear model presented the best fit with the highest coefficient of determination, with R<sup>2</sup> of 0.6420. With this, it is concluded that through the NDVI data it was possible to obtain the coffee LAI. In this way, the NDVI can be used to estimate the LAI.

**KEYWORDS:** Precision coffee crop ; Remote Sensing; UAV

**INTRODUÇÃO:** O café é um dos produtos agrícolas de maior importância do país. De acordo com os dados do boletim da CONAB (2022), sobre o primeiro levantamento de café na safra 2022, a área total cultivada no país com café (arábica e conilon) é de 2.236,99 milhões hectares. A expectativa de produção estimada em aproximadamente 56 mil sacas de café beneficiado, com um acréscimo de 16,8% superior em relação a 2021. Neste cenário, a primeira estimativa da safra 2022 em Minas Gerais é de produção de 26,997 mil sacas de café beneficiado.

Por ser significativo na economia brasileira, a aquisição de dados precisos em tempo ágil com custo baixo sobre a cultura cafeeira é de grande importância. Atualmente, informações sobre a cafeicultura são encontradas no IBGE (Instituto Brasileiro de Geografia e Estatística) e CONAB (Companhia Nacional de Abastecimento). Contudo, com o Sensoriamento Remoto pode-se obter dados precisos, em menor tempo de aquisição e com menor custo, o qual refere-se ao principal problema na cafeicultura, segundo Duarte e Brito (2007).

A agricultura de precisão agrega técnicas que permitem acessar e monitorar a atividade agrícola em nível local, com objetivo de aumentar a eficiência com base no manejo diferenciado de áreas na agricultura (Queiroz et al., 2000). Desse modo, dados procedentes de sensores embarcados em Aeronave Remotamente Pilotadas (Remotely Piloted Aircraft- RPA), conhecidos popularmente pela nomenclatura de VANTs e drones, podem ser utilizados para caracterizar, gerenciar e monitorar atividades agrônômicas e agrícolas, visto que, auxiliam na tomada de decisão por meio das informações obtidas periodicamente em diferentes áreas de pesquisa (Santos et al., 2019). Assim, seu progressivo uso na agricultura proporciona subsídios através de estudos com Índices de Vegetação (IV) e correlações com informações acerca das áreas de estudos.

O conhecimento do Índice de Área Foliar (IAF) da planta permite a estimativa da perda de água, uma vez que, as folhas são os principais órgãos que participam no processo transpiratório, responsável pela troca gasosa com o ambiente (Pereira et al., 1997). O Índice de Vegetação da Diferença Normalizada (NDVI) é uma relação entre as reflectâncias das bandas do infravermelho próximo e do vermelho e varia entre -1 a +1, em que os valores maiores estão associados a maior vigor vegetativo (Silva et al., 2007) o qual possibilita analisar as necessidades e estresses apresentados pelas culturas agrícolas e dessa forma faz-se possível definir melhores estratégias de manejo para a finalidade agrícola.

Dessa forma, o objetivo deste estudo foi avaliar a correlação entre dados de IAF e NDVI de imagens aéreas obtidas por RPA de duas cultivares cafeeiras diferentes de modo a ajustar um modelo empírico entre tais variáveis.

**MATERIAIS E MÉTODOS:** A região de estudo se localiza no município de Santo Antônio do Amparo, no Sul de Minas Gerais. O local estudado caracteriza-se por altitude média de 969m, com predominância de Latossolo Vermelho Amarelo Distrófico, contendo um clima, pela classificação de Koppen, denominado por Cwa, tropical de altitude, com temperaturas moderadas de verão chuvoso e quente (Alvares, 2013). A área de pesquisa refere-se a Fazenda Samambaia, situada entre os meridianos 506000 e 508000 m W Gr., e paralelos 7680000 e 7690000 m S, na projeção UTM zona 23 S e referencial geodésico SIRGAS 2000. A propriedade contém área de lavoura cafeeira (*Coffea Arabica* L.) com cultivares Catucaí (2SL) e Bourbon (IAC J10) ambos com 0,6 hectares (FIGURA 1).



FIGURA 1. Áreas e pontos amostrais: a) Catucaí (2SL) e b) Bourbon (IAC J10). **Sample areas and points: a) Catucaí (2SL) and b) Bourbon (IAC J10).**

As imagens foram obtidas no dia 26 de maio de 2019 por meio de uma RPA Multirrotor 3DR SOLO (3DR ROBOTICS, 2018) acoplado a uma camera multiespectral Parrot Sequoia, com resolução RGB de 16 MP, distância focal de 4,88 mm, resolução de banda única de 1,2 MP e distância focal de 3,98 mm e valores de refletância descritos nas bandas espectrais de verde (550 a 590 nm), vermelho (660 a 700 nm), borda vermelha (735 a 745 nm), infravermelho próximo (760 a 820 nm) e RGB (380 a 720 nm) (PARROT, 2018). O plano de voo foi programado no Software Mission Planner (2010) com definições de altura de voo de cinquenta metros, velocidade de 8 m/s e sobreposição de 80%.



Através do software PhotoScan da Agisoft (2017) versão 1.2.4 foi realizado o processamento de imagens com a geração dos ortomosaicos e pelos softwares QGIS 3.6.2 foram realizados os cálculos entre bandas para obtenção do NDVI. O NDVI foi calculado a partir da equação 1 descrita por Rouse et al. (1973). As plantas foram identificadas na imagem aérea por meio de placa de identificação/controle. O NDVI foi obtido pela segmentação das plantas de maneira manual e então extraído o valor médio por planta amostral.

$$NDVI = (R_{NIR} - R_R) / (R_{NIR} + R_R) \text{ Eq. (1)}$$

Onde:

NDVI – Índice de Vegetação de Diferença Normalizada (adimensional)

RNIR – Reflectância da banda do NIR

RR – Reflectância da banda do vermelho.

Os parâmetros medidos em campo foram a altura da planta (m) e diâmetro de copa (m). Os dados foram obtidos de vinte plantas distribuídas no terreno de maneira homogênea, referente a três pontos amostrais com quatro plantas em cada ponto amostral, segundo a metodologia de Ferraz et al. (2017). Com os dados coletados em campo foi possível estimar o IAF por meio da equação 2, desenvolvida por Favarin et al. (2002).

$$IAF = 0,0134 + 0,7276 \times D^2 \times h \text{ Eq. (2)}$$

Onde:

IAF - índice de área foliar (adimensional)

D - diâmetro das plantas (m)

h - altura das plantas (m).

Foram correlacionados os dados do IAF com os dados de NDVI em ambiente de planilha eletrônica com obtenção dos coeficientes de correlação de Pearson (R), coeficiente de determinação (R<sup>2</sup>) e equação para as regressões do tipo linear, exponencial, log e potência. A estimativa de equações por dados obtidos por sensores remotos á dados coletados em campo otimiza as atividades in situ, pois na maioria das vezes os dados coletados em campo demandam maior tempo e mão de obra em relação aos dados obtidos por imagens aéreas, deste modo contribui para uma gama de possibilidades de investigação de fatores influentes na atividade desenvolvida no campo, entretanto cabe destacar a importância da coleta de dados em campo para demonstrar a possibilidade de estudos que correlacionam as informações de verdade de campo.

**RESULTADOS E DISCUSSÃO:** A estatística descritiva para os dados de IAF, NDVI, altura e diâmetro para os pontos amostrais encontram-se descritos na Tabela 1.

**TABELA 1 – Estatística descritiva para as variáveis de IAF (cm), NDVI, ALTURA (cm) e DIÂMETRO (cm) para duas cultivares de café, Catucaí e Bourbon no mês de Maio de 2019. Descriptive statistics for the variables of LAI (cm), NDVI, HEIGHT (cm) and DIAMETER (cm) for two coffee cultivars, Catucaí and Bourbon, in May de 2019.**

Cultivar	Variável	Média	Desvio Padrão	Mediana	Máximo	Mínimo
Catucaí	IAF	0.0516	0.0192	0.0562	0.0873	0.0211
	NDVI	0.6914	0.0738	0.7139	0.7885	0.5403
	ALTURA	36.4000	6.0298	34.5000	50.0000	27.0000

	DIÂMETRO	36.6000	7.9565	38.5000	51.0000	25.0000
	IAF	0.0469	0.0188	0.0461	0.0887	0.0192
	NDVI	0.6683	0.0848	0.6771	0.8078	0.5296
Bourbon	ALTURA	39.7000	5.6205	40.0000	53.0000	30.0000
	DIÂMETRO	36.2500	6.7424	34.5000	50.0000	24.0000

Por meio dos dados obtidos para o mês em estudo, observou-se que os cafeeiros da cultivar Catucaí apresentaram valores de NDVI variando entre 0,5403 a 0,7885 e os valores da cultivar Bourbon variam entre 0,5296 a 0,8078. Isto se dá devido a diferença das bandas no vermelho (V) e no infravermelho próximo (NIR) em relação a reflectância (ROUSE et al., 1973). Ressalta-se que áreas de vegetação com maior vigor demonstram indicativos de maiores valores de NDVI e com menores valores apresentam um menor vigor (Boratto e Gomide, 2013). Observou-se por sua vez que as plantas cafeeiras da cultivar Catucaí demonstram valores variantes de IAF entre 0,0211 a 0,0873 e a cultivar Bourbon entre 0,0192 a 0,0887, devido a característica do crescimento e desenvolvimento da comunidade vegetal de estudo. O desvio padrão, por sua vez, indicativo de medida de dispersão dos conjuntos de dados demonstra baixa variação para os dados de IAF e NDVI e maior variação entre os dados de altura e diâmetro de copa

A utilização do NDVI como indicador de IAF vem sendo bastante utilizado para monitorar a cobertura e o vigor da vegetação através de imagens de sensores multiespectrais (Parise e Vettorazzi, 2005). Visto que as técnicas de Sensoriamento Remoto se mostram como uma ótima alternativa em relação ao benefício de otimização de tempo no campo, uma vez que após validada a metodologia e estimativa de equações que correlacionam as informações não há necessidade de mensuração planta-a-planta. Deste modo, a cultivar Catucaí apresentou R de 0,6134 e a cultivar Bourbon R de 0,6420 com considerações de moderada a elevada correlação entre os dados de estudos com modelos ajustados e respectivos R<sup>2</sup> descritos na TABELA 2.

**TABELA 2 – Modelos testados, coeficiente de determinação (R<sup>2</sup>) e equação ajustadas para as duas cultivares cafeeiras, Catucaí e Bourbon, no mês de Maio de 2019, sendo variável x NDVI e variável y IAF. Tested models, determination coefficient (R<sup>2</sup>) and adjusted equation for the two coffee cultivars, Catucaí and Bourbon, in Maio de 2019, being variable x NDVI and variable y LAI.**

Cultivar	Modelo	R <sup>2</sup>	Equação
Catucaí	Linear	0.6135	$y = 3.0062x + 0.5363$
	Exponencial	0.6171	$y = 0.5438e^{4.5422x}$
	Log	0.6939	$y = 0.1474\ln(x) + 1.1396$
	Potência	0.7055	$y = 1.3581x^{0.2239}$
Bourbon	Linear	0.6420	$y = 4.0615x + 0.4937$
	Exponencial	0.6130	$y = 0.5168e^{5.7868x}$
	Log	0.5672	$y = 0.1707\ln(x) + 1.2203$
	Potência	0.5517	$y = 1.4655x^{0.2455}$

Os modelos ajustados apresentaram bom desempenho. Além disso, observou-se que, para a cultivar Catucaí, o modelo potência apresentou o melhor ajuste com R<sup>2</sup> de 0,7055. Para cultivar Bourbon, o modelo linear apresentou o melhor ajuste com R<sup>2</sup> de 0,6420, sendo possível evidenciar a utilização de tais modelos para mensuração de IAF em cultivares cafeeiras recém transplantadas por meio de dados de NDVI.

**CONCLUSÃO:** Por meio dos dados de NDVI obtidos de imagens aéreas capturadas por RPA foi possível ajustar modelos de regressão para obtenção do IAF das cultivares cafeeiras em estudo. Assim, demonstra-se que o NDVI é um bom identificador de vigor para o acompanhamento dos cafezais.

#### **AGRADECIMENTOS:**

À Embrapa Café – Consórcio Pesquisa Café, pelo financiamento conforme projeto aprovado nº 10.18.20.041.00.00, Universidade Federal de Lavras- UFLA, ao Programa de Pós-Graduação em Engenharia Agrícola – PPGEA, a CAPES, FAPEMIG e CNPq.

#### **REFERÊNCIAS**

COMPANHIA NACIONAL DE ABASTECIMENTO- CONAB. **Acompanhamento da safra brasileira: café** – v. 6, n. 2 (2022) – Brasília: Conab, 2021. Disponível em: <<http://www.conab.gov.br>>. ISSN 2318-7913. Acesso em: abril, 2022.

BORATTO, I. M. P.; GOMIDE, R. L. Aplicação dos índices de vegetação NDVI, SAVI e IAF na caracterização da cobertura vegetativa da região Norte de Minas Gerais. In: Simpósio Brasileiro de Sensoriamento Remoto, 2013, Foz do Iguaçu. **Anais...** São José dos Campos: INPE, 2013. p. 891-898.

FAVARIN, J. L.; et al.; Equações para a estimativa do índice de área foliar do cafeeiro. **Pesquisa Agropecuária Brasileira**, Brasília, v.37, n.6, p.769-773, 2002.

FERRAZ, G. A. E S.; et al.; Variabilidade espacial dos atributos da planta de uma lavoura cafeeira. **Rev. Ciênc. Agron.** Fortaleza, v. 48, n. 1, p. 81-91, 2017.

PARISE, F.J.O.; VETTORAZZI, C.A.; Análise de dados de produção em um pomar jovem de laranjeiras Hamlin: I. Relações com a resposta espectral. **Revista Brasileira de Fruticultura**, v.27, n.1, abr.2005

ROUSE, J. W.; et al.; Monitoring vegetation systems in the Great Plains with ERTS. **Third ERTS Symposium**, 1, 309–317, 1973.

SANTOS, L. M. D.; BARBOSA, B. D. S.; ANDRADE, A. D. Use of remotely piloted aircraft in precision agriculture: a review. **Dyna**, v. 86, n 210, p. 284-291. 2019.

SILVA, M.R.; RIBEIRO, M.G.; CENTENO, J.A.S.; Monitoramento de estiagens com imagens MODIS. In: XIII Simpósio Brasileiro De Sensoriamento Remoto, Abril, 2007. Florianópolis, SC, **Anais...** 2007.

# VARIABILIDADE ESPACIAL E TEMPORAL ENTRE TALHÕES DE *COFFEA ARABICA*

Eudocio Rafael Otavio da Silva<sup>1</sup>; Thiago Lima da Silva<sup>2</sup>; Ricardo Augusto de Souza<sup>3</sup>; Marcelo Chan Fu Wei<sup>2</sup>; José Paulo Molin<sup>4</sup>

<sup>1</sup>Eng<sup>o</sup> Agrícola e Ambiental, Doutorando - Depto. Engenharia de Biossistemas, ESALQ, USP, Piracicaba - SP. eudocio@usp.br / (21) 9 7234-5249; <sup>2</sup>Eng<sup>o</sup> Agrônomo, Doutorando - Depto. Engenharia de Biossistemas, ESALQ, USP, Piracicaba - SP; <sup>3</sup>Eng<sup>o</sup> Agrônomo, Doutorando - Depto. de Produção Vegetal, ESALQ, USP, Piracicaba - SP; <sup>4</sup>Eng<sup>o</sup> Agrícola, Professor - Depto. Engenharia de Biossistemas, ESALQ, USP, Piracicaba - SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** A produtividade do cafeeiro apresenta variação mesmo entre plantas, porém o seu monitoramento e gestão ainda enfrentam dificuldades operacionais e a abordagem da variabilidade entre talhões pode ser uma estratégia simples e eficaz às diferenças climatológicas, tratamentos culturais, aplicação de corretivos e fertilizantes e aos efeitos da bienalidade. Este estudo teve como objetivo investigar a variabilidade espacial e temporal da produtividade e de atributos químicos do solo entre talhões de cafeeiros e verificar a magnitude da bienalidade ao longo de quatro safras a partir de uma abordagem por células. Para isto, foram utilizados dados de série histórica de quatro safras obtidas dos talhões de café de duas fazendas localizadas no município de Silvianópolis, MG, Brasil. A partir da abordagem, considerando-se os talhões como células, foram obtidos dados da produtividade e de atributos químicos do solo ao longo de quatro anos e foi realizado o mapeamento espacial e temporal destas variáveis a nível de talhão. Na ausência de recursos para monitoramentos e intervenções em elevada resolução espacial, a abordagem tendo os talhões como unidades representa um avanço. A investigação e identificação da variabilidade espacial e temporal da produtividade do café e dos atributos químicos do solo, como a saturação por bases (V%), mostrou-se eficaz como ferramentas para gestão localizada em cafezais a nível de talhão. O mapeamento da magnitude do efeito bienal do café em nível de talhão demonstrou ser uma potencial ferramenta que possibilita a geração de estratégias pelo produtor para lidar com este efeito na cultura do café.

**PALAVRAS-CHAVE:** Amostragem por células; Bienalidade; Cafeicultura de precisão

## SPATIAL AND TEMPORAL VARIABILITY BETWEEN *COFFEA ARABICA* FIELDS

**ABSTRACT:** Coffee yield varies even between plants, but its monitoring and management still face operational difficulties and the approach of the variability between stands can be a simple and effective strategy to the climatological differences, cultural treatments, application of correctives and fertilizers and the effects of the biennial. This study aimed to investigate the spatial and temporal variability of yield and soil chemical attributes between fields in coffee plantations and to verify the magnitude of bienniality over four seasons from a cell-based approach. For this, historical series data from four crops obtained from coffee fields on two farms located in the municipality of Silvianópolis, MG, Brazil were used. From the approach having the fields as cells, data on yield and chemical attributes of the soil were obtained over four years and the spatial and temporal mapping of these variables was carried out at the field level. In the absence of resources for monitoring and interventions in high spatial resolution, the approach having the fields as units represents an advance. The investigation and identification of the spatial and temporal variability of coffee yield and soil chemical attributes, such as base saturation (V%), on the two farms, proved to be an effective approach that can contribute to localized management in coffee plantations at the same level of field. The mapping of the magnitude of the biennial effect of coffee at the field level proved to be a potential tool that allows the generation of strategies by the producer to deal with this effect on the coffee crop.

**KEYWORDS:** Cell sampling; Biennial effect; Precision coffee growing

**INTRODUÇÃO:** A cafeicultura no Brasil é uma das atividades agrícolas de grande destaque devido à importância que a cultura apresenta na economia interna. A primeira estimativa da CONAB em 2022 para a

cafeicultura é que sejam destinados 2.236,99 mil hectares, sendo que deste total 1.809,98 mil hectares sejam do tipo arábica. A produção total é estimada em 55.743,00 mil sacas beneficiadas, apresentando incremento de 16,8% em relação à safra de 2021, com produtividade média nacional de 30,6 sacas ha<sup>-1</sup>, aumento de 16,1% em relação à safra anterior, reflexo do efeito da bienalidade (CONAB, 2022). A produtividade do café apresenta variação intra e inter talhão, porém o seu monitoramento e gestão ainda enfrentam dificuldades operacionais. Nesta perspectiva, ferramentas da Agricultura de Precisão (AP) podem ser úteis no monitoramento constante e na investigação da variabilidade espacial e temporal da produtividade do cafeeiro e da nutrição destes solos. Isto pode ser exposto através de mapas de produtividade e de atributos do solo que contribuam no entendimento do histórico de produção da fazenda e suas relações de causa e efeito na lavoura. São diversas as abordagens para investigação da variabilidade espacial em lavouras de café, podendo ser obtidas informações de alta precisão e acurácia (BAZAME et al., 2021). Entretanto, quando não estão disponíveis dados de alta resolução espacial a amostragem por células pode ser uma ferramenta eficaz para pequenas unidades produtivas. Neste tipo de amostragem o campo é dividido em subáreas denominadas células e o resultado obtido de uma amostra composta da variável de interesse representa toda a área da célula (GIMENEZ & ZANCANARO, 2012). Como não é recorrente na rotina do produtor a realização de amostragem por pontos georreferenciados e geração de mapas de produtividade do cafeeiro, a abordagem por células pode servir para o entendimento e a lidar com a variabilidade existente. Desta maneira, a abordagem da variabilidade entre talhões pode ser uma estratégia simples e eficiente às diferenças climatológicas, tratos culturais, aplicação de corretivos e fertilizantes e aos efeitos da bienalidade do café. Este estudo propõe que pequenos talhões de café podem servir como células para o entendimento da variabilidade espacial e temporal na fazenda. Sendo assim, teve-se como objetivo investigar a variabilidade espacial e temporal da produtividade e de atributos químicos do solo entre pequenos talhões em cafezais e verificar a magnitude da bienalidade ao longo de quatro safras a partir de uma abordagem por células.

**MATERIAIS E MÉTODOS:** O estudo foi realizado em duas fazendas com cultivo comercial de *Coffea arabica* L., localizadas no município de Silvianópolis, sul do Estado de Minas Gerais, Brasil. De acordo com a classificação climática de Köppen, o clima da região é do tipo Cwa, apresentando temperaturas moderadas e verões quentes e chuvosos (MARTINS et al., 2018). A fazenda 1 possui 15 talhões com sistema de cultivo convencional de cafeeiros em produção das variedades Mundo Novo 376-4 e Catuaí Vermelho, com área total de 87,70 ha, coordenadas UTM 7.568.016,00 m N, 409.456,00 m E (Fuso 23) e altitude de 877,00 m. A fazenda 2 é constituída de 10 talhões com sistema de cultivo convencional de cafeeiros em produção das variedades Mundo Novo 376-4, Catuaí Amarelo, Catuaí Vermelho e Topázio, com área total de 73,37 ha, com coordenadas UTM 7.572.396,00 m N, 410.537,00 m E (Fuso 23) e altitude de 950,00 m (Figura 1).

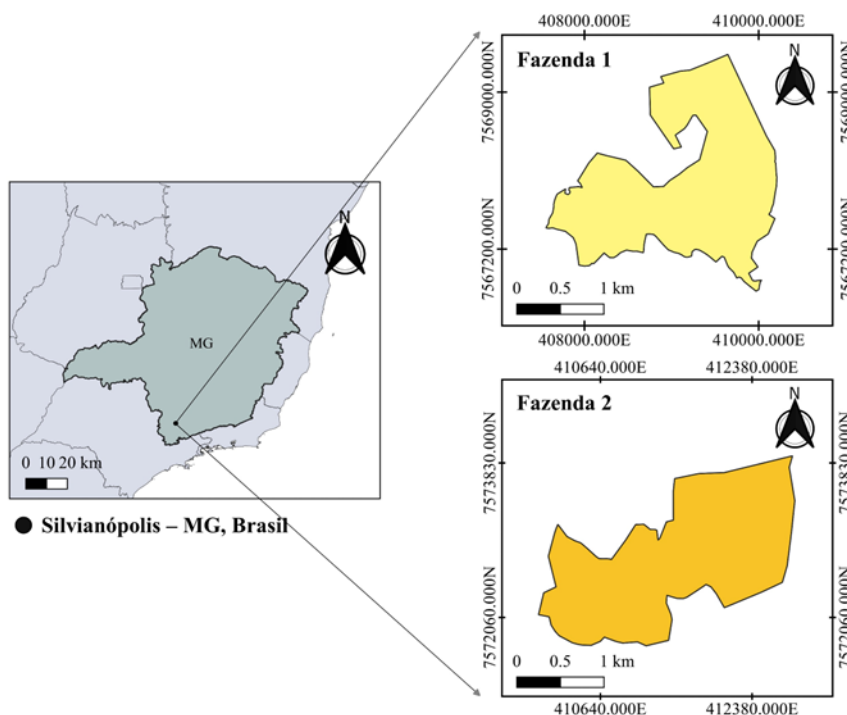


FIGURA 1. Localização geográfica das fazendas 1 e 2, município de Silvianópolis, sul do Estado de Minas Gerais. **Geographic location of farms 1 and 2, municipality of Silvianópolis, south of Minas Gerais State.**

As classes de solos predominantes nas fazendas são Argissolo Vermelho-Amarelo e o Latossolo Vermelho-Amarelo, distróficos (SANTOS et al., 2018). Os dados utilizados neste estudo foram coletados de cada talhão pela administração das fazendas em 2018, 2019, 2020 e 2021. Os dados de produtividade, atributos do solo e estado de plantas foram extraídos de dados médios em cada talhão (Figura 2).

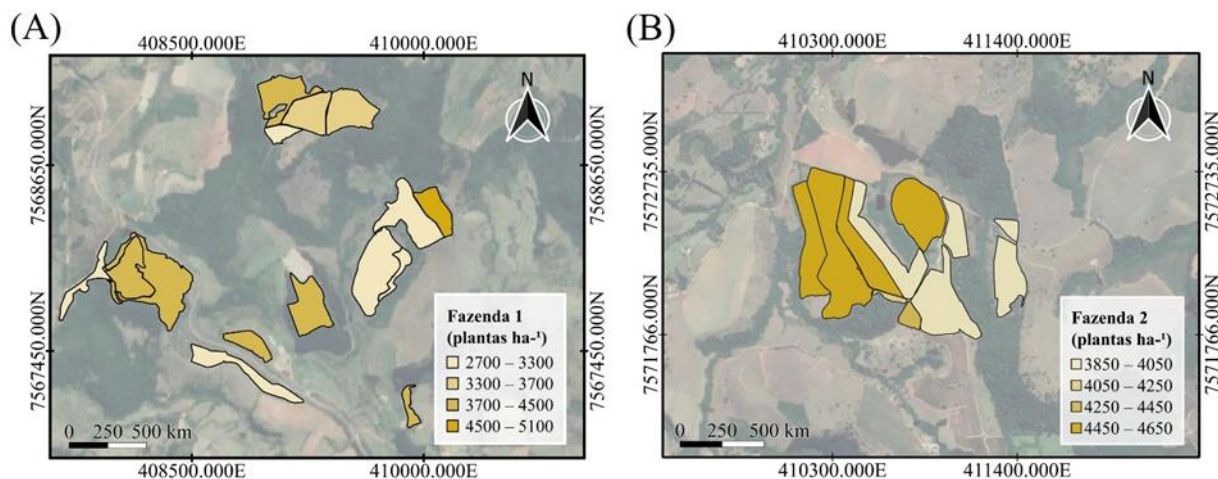


FIGURA 2. Estado de plantas  $ha^{-1}$  nos talhões da fazenda 1 (A) e 2 (B). **Plant stand  $ha^{-1}$  in the stands of farm 1 (A) and 2 (B).**

Como os talhões são relativamente pequenos, considerou-se cada um como sendo células (MOLIN et al., 2015), para efeito de monitoramentos referentes à amostragem de solo e produtividade. Assim, totalizou-se 25 células correspondentes às duas fazendas. Foram coletadas amostras de solo deformadas, na profundidade de 0-0,20 m na qual uma amostra era composta por 20 subamostras, nos anos de 2018, 2019, 2020 e 2021. Os dados de produtividade foram obtidos com base na massa de café úmido (Figura 3). Nas áreas com declividade inferior a 30% a colheita foi realizada mecanicamente utilizando colhedoras automotrizes de café. Nas áreas com declividades superiores a 30% a colheita foi semi-mecanizada, realizada com o suporte de derriçadeiras. A produtividade foi mensurada pelo volume de café, utilizando como referência um volume de 60L, e depois convertido em sacas por hectares.

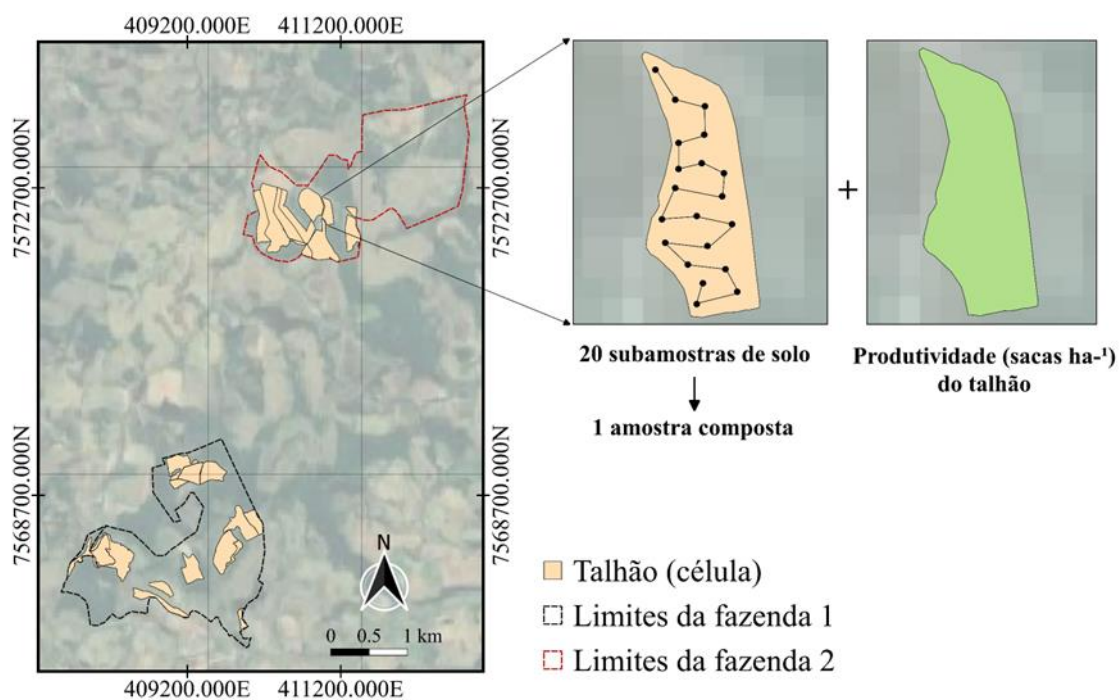


FIGURA 3. Obtenção das amostras de solo por amostragem por células e obtenção dos dados de produtividade do café considerando os talhões como células. **Obtaining soil samples by cell sampling and obtaining coffee yield data considering the fields as cells.**

Stevens (1949) sugeriu que a magnitude da bienalidade do café pode ser medida pela subtração da média da produção dos anos de alta produção pelos anos de baixa produção, trabalhando em números pares. Desta maneira, subtraiu-se os dados médios de produtividade dos anos de alta e de baixa produção para cada talhão nas fazendas 1 e 2 (Eq. 1).

$$P_{\text{talhão}} = \frac{(P_1 + P_2)}{2} - \frac{(P_3 + P_4)}{2} \quad (\text{Eq. 1})$$

Em que:  $P_1, P_2$  = valor médio da produtividade no talhão nos anos de maiores produções, sacas  $\text{ha}^{-1}$ ;  $P_3, P_4$  = valor médio da produtividade no talhão nos anos de menores produções, sacas  $\text{ha}^{-1}$ .

Foram realizadas análises de atributos químicos dos solos ao longo dos anos em cada talhão. Os atributos analisados foram pH em água, cálcio (Ca), magnésio (Mg), alumínio (Al) e potássio (K) trocáveis, fósforo (P) assimilável e acidez potencial (H+Al) segundo Teixeira et al. (2017). A partir dos teores de nutrientes no solo foram obtidos os dados sobre a capacidade de troca de cátions total (CTC) e saturação por bases (V%) (GARÇONI & SOBREIRA, 2017; TEIXEIRA et al., 2017). Para a avaliação da análise descritiva e exploratória dos dados utilizou-se o programa R Studio 3.5.1. Foram obtidos de cada atributo os valores mínimos, médios, máximos, coeficiente de variação (CV), desvio padrão, assimetria e curtose, assim como identificados valores discrepantes. Os mapas de variabilidade espacial e temporal das variáveis de interesse foram gerados por meio do programa Quantum Gis 3.10.10 (QGIS).

**RESULTADOS E DISCUSSÃO:** Os resultados da estatística descritiva estão apresentados na Tabela 1. Observou-se que durante as safras dos quatro anos estudados houve variabilidade na produtividade entre as fazendas 1 e 2.

TABELA 1. Estatística descritiva da produtividade do café nas safras de 2018 a 2021 nas fazendas 1 e 2. **Descriptive statistics of coffee yield in the 2018 to 2021 crops on farms 1 and 2**

Produtividade nas safras de 2018, 2019, 2020 e 2021 (Sacac $\text{ha}^{-1}$ )							
	Mínimo (sacas $\text{ha}^{-1}$ )	Máximo (sacas $\text{ha}^{-1}$ )	Média	Total (sacas $\text{ha}^{-1}$ )	Desvio padrão	Assimetria	Coeficiente de variação (%)
Fazenda 1	0	129,55	29,21	1.752,54	26,17	1,69	89,61
Fazenda 2	0	85,81	19,59	783,38	20,88	0,83	100,00

Verifica-se que o coeficiente de variação apresentou valores acima de 60% indicando alta variabilidade pela classificação proposta por Warrick & Nielsen (1980), indicando a heterogeneidade de produtividade dos talhões nas fazendas 1 e 2. A variabilidade da produtividade toma como base a amplitude dos valores mínimos e máximos verificados nos talhões, como valores mínimos iguais a zero (0) e máximos iguais a 129,00 e 85,81 sacas  $\text{ha}^{-1}$ , respectivamente nas fazenda 1 e 2, corroborando com altos valores de desvio padrão, coeficiente de variação e a assimetria afastada de zero, indicando um distanciamento da distribuição normal. As produtividades nulas são resultado do esqueletamento praticado nestes talhões. A variabilidade da produtividade verificada nas fazendas pode ser decorrente da variação de estande, espaçamentos entre plantas e classes de solos presentes nos talhões, além da influência do manejo de adubação estabelecido para cada talhão e da bienalidade. Segundo Andrade et al. (2015) a influência do arranjo espacial menores do café na produtividade pode ser positiva entre plantas na linha, porém conclusões sobre variabilidade de produtividade em café não podem ser baseado apenas em combinações de espaçamentos devido à complexidade de interações que envolve o sistema de produção. Os valores de produtividades médias da produção de café nas fazendas nos anos de 2018 a 2021 podem ser visualizados na Figura 4.






FIGURA 4. Produtividades médias (sacas ha<sup>-1</sup>) da produção de café nas fazendas 1 e 2 nos anos de 2018 a 2021. **Average coffee yield (sacas ha<sup>-1</sup>) on farms 1 and 2 in the years 2018 to 2021.**

A partir dos valores médios de produtividade do café observados é possível verificar a variação temporal da produtividade dos cafezais, caracterizada pela bienalidade positiva nos anos de 2018 e 2020 nas fazendas 1 e 2. Para ser entendida, a variabilidade da produtividade necessita de ferramentas tecnológicas de auxílio devido à complexidade das interações existentes entre variáveis de solo, clima e o comportamento agrônômico da cultura. Segundo Ferraz et al. (2017) informações retiradas de dados de produtividade em conjunto com a observação de mapas podem contribuir para encontrar os motivos da ocorrência da variabilidade da produtividade, principalmente em se tratando de baixas produtividades, como as ocorridas em 2019 e 2021, e permitem que na próxima safra estes problemas possam ser minimizados. Desta forma, o cafeicultor pode planejar de forma eficaz com base em informações históricas das áreas mapeadas e tomar as decisões que proporcionem um melhor desempenho produtivo da cultura. Os mapas da variabilidade temporal e espacial são ferramentas de orientação para o sistema de produção da cafeicultura, pois podem demonstrar fatores que influenciam na variabilidade da produtividade como a bienalidade, fertilidade do solo, nutrição das folhas, pragas e doenças (CARVALHO et al., 2017). As Figuras 5 e 6 apresentam os mapas de produtividade das fazendas 1 e 2, respectivamente, de 2018 a 2021.

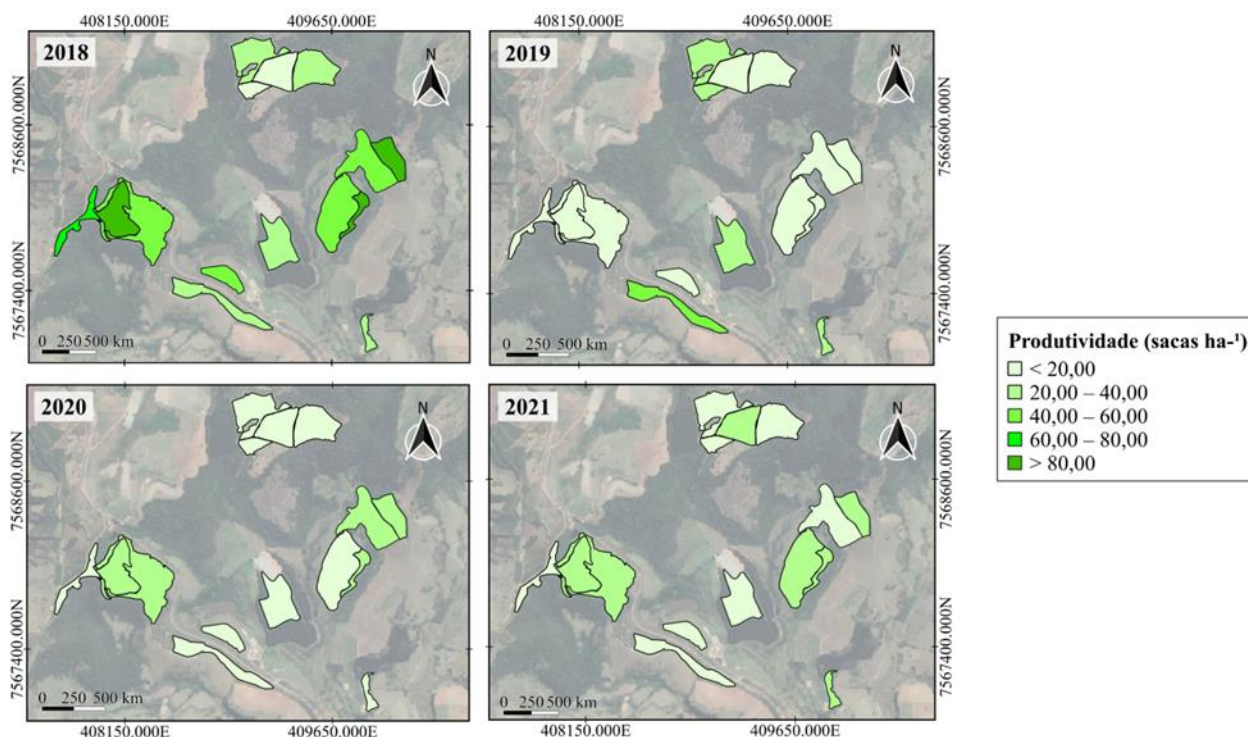


FIGURA 5. Mapas da variabilidade espacial e temporal da produtividade de café na fazenda 1 nos anos de 2018, 2019, 2020 e 2021. **Maps of spatial and temporal variability of coffee yield on farm 1 in the years 2018, 2019, 2020 and 2021.**



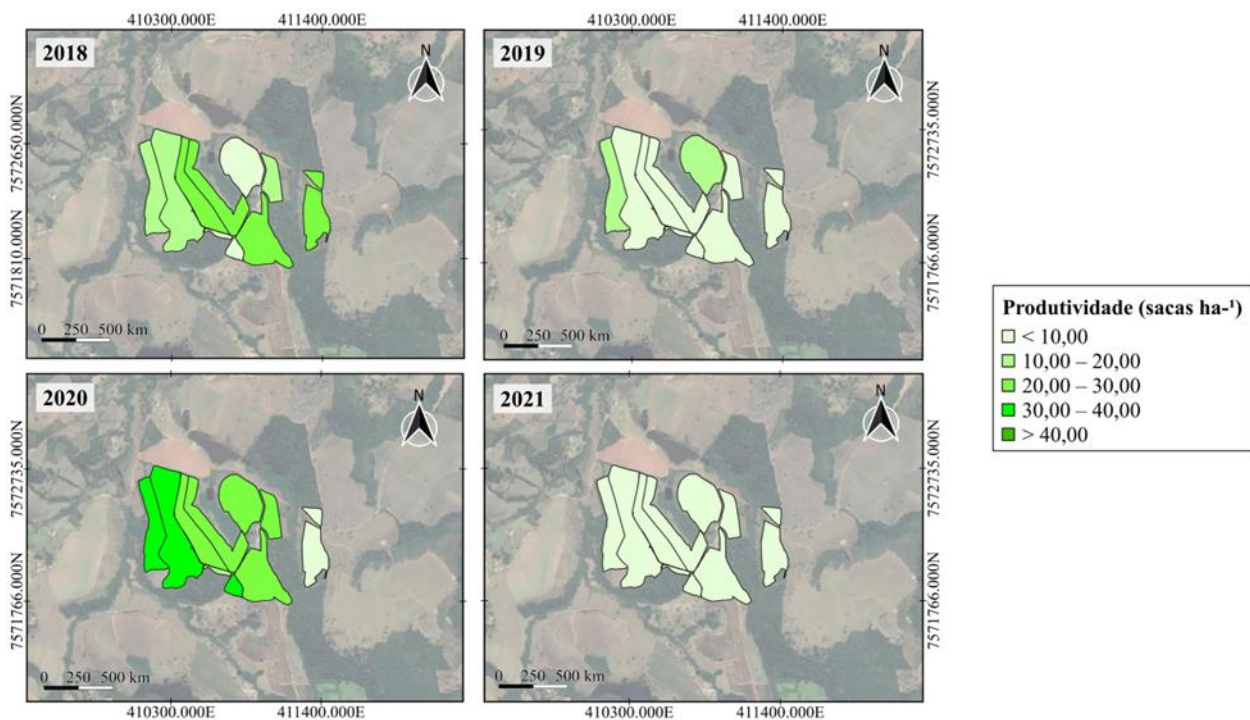


FIGURA 6. Mapas da variabilidade espacial e temporal da produtividade de café na fazenda 2 nos anos de 2018, 2019, 2020 e 2021. **Maps of spatial and temporal variability of coffee yield on farm 2 in the years 2018, 2019, 2020 and 2021.**

Verifica-se que nos anos de bialidade positiva (2018 e 2020) existe produtividade maior, possivelmente influenciado por talhões onde grande parte das plantas conseguiram recuperação fisiológica para expressão de maior produtividade na bialidade ou mesmo responderam positivamente ao manejo de poda e adubações aplicadas durante o período de bialidade negativa. Para Carvalho et al. (2017) uma comparação visual entre mapas pode demonstrar a ocorrência de bialidade na produtividade, pois as regiões que tiveram as maiores produtividades apresentaram os maiores valores. Neste caso, observa-se que os talhões que utilizaram suas reservas para frutificação, influenciando negativamente no crescimento dos ramos e, conseqüentemente, reduzindo a produtividade em anos de bialidade negativa, foram observados no mapa nos anos de 2019 e 2021. No ano de 2019 e 2021, anos de bialidade negativa, observa-se uma variabilidade e produtividade menor nos talhões. Para Rodrigues et al. (2013) esta característica na cultura do café ocorre devido ao processo de alocação dos fotoassimilados em anos de alta produtividade para enchimento dos grãos e isso prejudica o crescimento das partes vegetativas da cultura, apresentando um rendimento menor no ano subseqüente. Nos anos de bialidade negativa, além das características fisiológicas da cultura, o produtor aplica tratos culturais mais específicos como correções e podas influenciando na produtividade. O esgotamento nas safras de 2018 e 2020 pode explicar valores baixos de produtividade dos talhões nos anos de bialidade negativa. Equilíbrio da disponibilidade de nutrientes no solo também pode influenciar na variabilidade da produtividade nas fazendas. Para contribuir no entendimento dos fatores que influenciam a variabilidade da produtividade, a Figura 7 exibe a variabilidade espacial e temporal da saturação por bases (V%) nos talhões das fazendas 1 e 2.

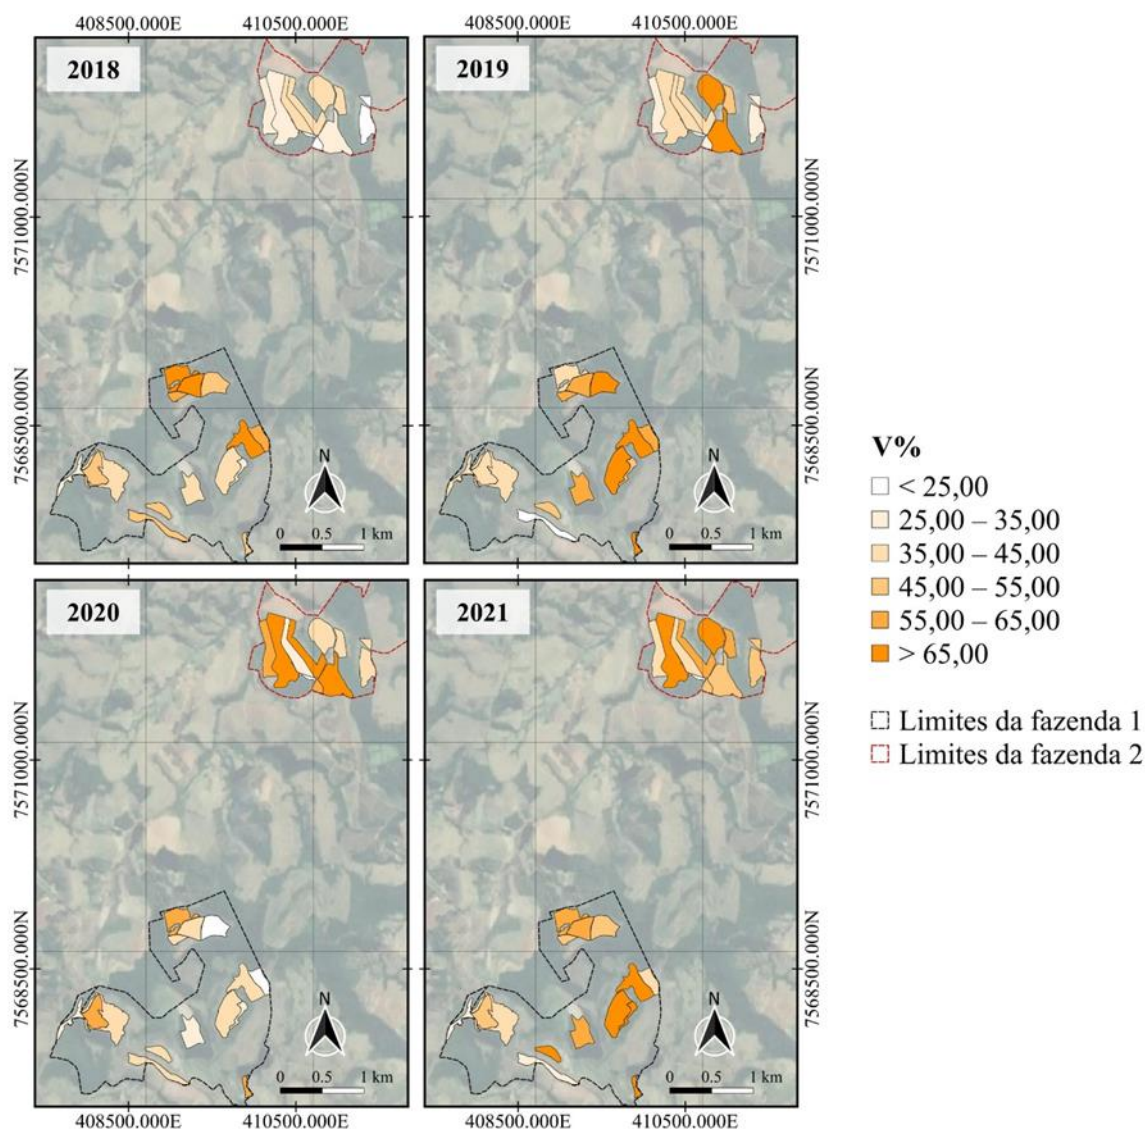


FIGURA 7. Variabilidade espacial e temporal da saturação de bases (V%) do solo nas fazendas 1 e 2. **Spatial and temporal variability of soil base saturation (V%) in farms 1 and 2.**

Os valores encontrados na análise do solo que apresentam V% abaixo de 60% podem ter contribuído para a observação desta variabilidade. Segundo Ribeiro et al. (1999) para a cultura do cafeeiro, o ideal de saturação por bases fica em torno de 60%, disponibilidade abaixo deste valor pode influenciar na produtividade e, conseqüentemente, aumentar a variabilidade dentro dos talhões. Utilizado no método da elevação da saturação de bases (GARÇONI & SOBREIRA, 2017), o mapeamento da V% permite identificar a variabilidade deste atributo no solo para a correção da acidez ou evitar supercalagem nas épocas de planejamento para preparação de safra. Estes dados juntamente aos dados de produtividade podem orientar os produtores na aplicação de insumos, assim como na redução de custos em operações nos cafezais. A magnitude da oscilação da bienalidade na produtividade do café pode contribuir para o entendimento do comportamento das safras (Figura 8).

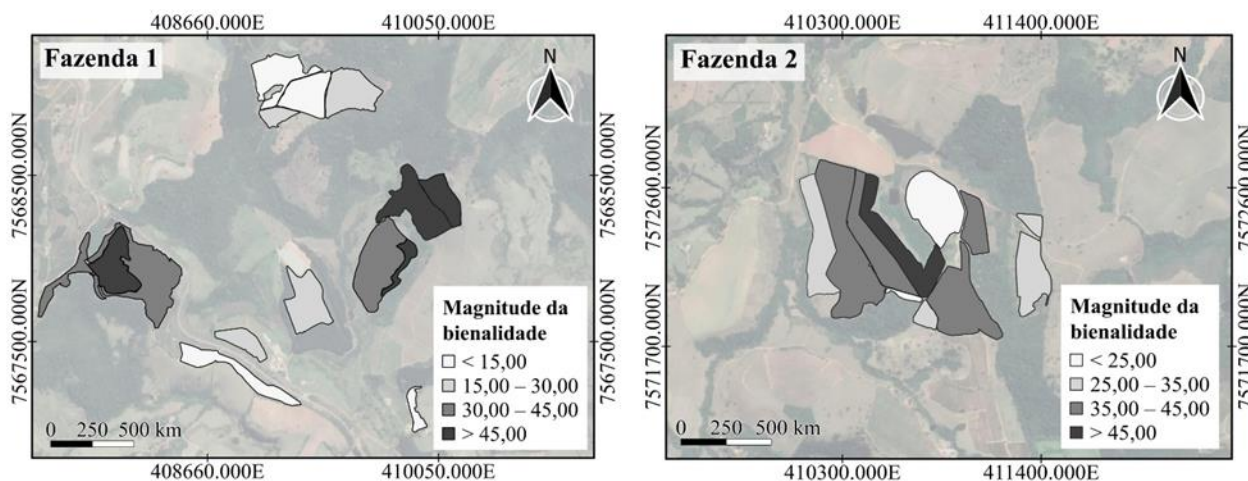


FIGURA 8. Magnitude da oscilação da bienalidade nos talhões nas fazendas 1 e 2 para os anos 2018, 2019, 2020 e 2021. **Magnitude of the biennial oscillation in the fields on farms 1 and 2 for the years 2018, 2019, 2020 and 2021.**

Verifica-se que a magnitude da oscilação da bienalidade do café foi obtida pela média dos anos de alta (2018 e 2020) e de baixa (2019 e 2021) produtividade do cafeeiro (STEVENS, 1949). Para magnitude da bienalidade, valores mais próximos a zero (0) significa que houve menor variabilidade na produtividade, ou seja, a alternância entre altas e baixas produtividades no ano subsequente foram próximas. Valendo-se também do contrário para os maiores valores de magnitude da bienalidade. É possível verificar que os talhões na fazenda 1 exibiram valores de magnitude da bienalidade que variaram em menos que 15 a maiores que 45, atingindo valores de 71,9. A fazenda 2, mesmo com um menor número de talhões quando comparados a fazenda 1, exhibe oscilações da variabilidade da magnitude da bienalidade menores que 25 a maiores que 45, atingindo magnitudes de 58,8. Segundo Pereira et al. (2011), o arranjo espacial mais adensado acentua os efeitos da bienalidade, pois nestes cultivos a variabilidade entre as colheitas é maior provocando a oscilação produtiva e gerando maior magnitude da bienalidade. Com a informação da variabilidade espacial e temporal dos efeitos da magnitude da bienalidade é possível dimensionar ações localizadas em nível de talhão que orientem o produtor. Uma vez que podem contribuir na realização de estratégias para lidar com os efeitos da bienalidade nas próximas safras. De maneira geral, a abordagem da variabilidade entre talhões de café por células pode auxiliar os produtores no manejo em pequenos talhões nas fazendas, sobretudo às ações relacionadas ao planejamento de adubação do solo, estabelecimento de tratos culturais e de novos espaçamentos no processo de renovação do cafezal, tendo um maior controle e gestão dos cafezais mesmo que em baixa resolução espacial.

**CONCLUSÃO:** Na ausência de recursos para monitoramentos e intervenções em elevada resolução espacial, a abordagem tendo os talhões como unidades representa um avanço. A investigação e identificação da variabilidade espacial e temporal da produtividade do café nas fazendas e dos atributos químicos do solo, como a saturação por bases (V%), apresentou-se como ferramenta eficaz e que pode contribuir na gestão localizada em cafezais em nível de talhão. O mapeamento da magnitude do efeito bienal do café em nível de talhão demonstrou ser uma potencial ferramenta que possibilita a geração de estratégias pelo produtor para lidar com este efeito na cultura do café.

#### REFERÊNCIAS

BAZAME, H.C; MOLIN, J.P.; ALTHOFF, D.; MARTELLO, M. Detection, classification, and mapping of coffee fruits during harvest with computer vision. **Computers and Electronics in Agriculture**, v.183, 2021.

CARVALHO, L.C.C.; SILVA, F.M.; FERRAZ, G.A.S.; STRACIERI, J.; FERRAZ, P.F.P.; AMBROSANO, L. Geostatistical analysis of Arabic coffee yield in tow crop. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.21, n.6, p.410–414, 2017.

COMPANHIA NACIONAL DE ABASTECIMENTO – CONAB. **Acompanhamento da safra brasileira café, v.9 – Safra 2022**, n. 1, Primeiro levantamento, Brasília-DF, p.1–60, 2022.

FERRAZ, G.A.S.; SILVA, F.M. da; OLIVEIRA, M.S. de; CUSTÓDIO, A.A.P.; FERRAZ, P.F.P. Variabilidade espacial dos atributos da planta de uma lavoura cafeeira. **Revista Ciência Agronômica**, v.48, n.1, p.81-91, 2017.

GIMENEZ, L.M.; ZANCANARO, L. Monitoramento da fertilidade de solo com a técnica da amostragem em grade. **Informações Agronômicas**, n. 138, p 19–25, 2012.

GUARÇONI, A.; SOBREIRA, F.M. Classical methods and calculation algorithms for determining lime requirements. **Revista Brasileira de Ciência do Solo**, v.41, p.1-11, 2017.

MARTINS, T.B.; ALMEIDA, G.C.; AVELAR, F.G.; BEIJO, L.A. Predição da precipitação máxima no município de Silvianópolis-MG: Abordagens clássica e bayesiana. **Irriga**, v.23, n.3, p.467–479, 2018.

MOLIN, J.P.; AMARAL, L.R.; COLAÇO, A.F. **Agricultura de Precisão**. 1. ed. São Paulo: Oficina de textos, 2015. p.238.

PEREIRA, S.P.; BARTHOLO, G.F.; BALIZA, D.P.; SOBREIRA, F.M.; GUIMARÃES, R.J. Crescimento, produtividade e bienalidade do cafeeiro em função do espaçamento de cultivo. **Pesquisa Agropecuária Brasileira**, v.46, n.2, p.152–160, 2011.

RIBEIRO, A.C.; GUIMARAES, P.T.G.; ALVAREZ, V.V.H. **Recomendações para o uso de corretivos e fertilizantes em Minas Gerais**. 5ª aproximação: Viçosa, CFSEMG, 1999. p.359.

RODRIGUES, W.N. et al. Crop yield bienniality in groups of genotypes of conilon coffee. **African Journal of Agricultural Research**, v.8, p.4422–4426, 2013.

SANTOS, H.G. et al. **Sistema Brasileiro de Classificação de Solos**. 5. ed. Brasília, DF: Embrapa, 2018. 356p.

STEVENS, W. L. Análises estatísticas do ensaio de variedades de café. **Bragantia**, v.9, n.5-8, p.103–123, 1949.

TEIXEIRA, P. C. et al. **Manual de métodos de análise de solo**. 3. ed. rev. e ampl. Brasília, DF: Embrapa, 2017. 573 p.

WARRICK, A.W. & NIELSEN, D.R. Spatial variability of soil physical properties in the field. In: HILLEL, D. (Ed.). **Applications of soil physics**. New York: Academic Press, 344p, 1980.



# USO DE IMAGENS MULTIESPECTRAIS em cultivar de cítrus da variedade Pêra (*Citrus sinensis* L. Osbeck) CULTIVADAS COM APLICAÇÃO DE GESSO AGRÍCOLA

ODAILSON RODRIGUES DO NASCIMENTO<sup>1</sup>; JAMILE DO NASCIMENTO SANTOS<sup>2</sup>; IZADORA DE CASSIA MESQUITA DA CUNHA<sup>3</sup>; FLAVIO HENRIQUE SANTOS RODRIGUES<sup>4</sup>; FABIO JÚNIOR DE OLIVEIRA<sup>5</sup>

<sup>1</sup>Eng<sup>o</sup> Agrônomo, Graduado - Campus Capitão Poço, UFRA, Capitão Poço - PA. odailsonrodrig@gmail.com / (91) 9 8251-7869; <sup>2</sup>Eng<sup>a</sup> Agrônoma, Mestranda em Produção Vegetal - Departamento de Engenharia e Ciências Exatas, UNESP, Jaboticabal - SP; <sup>3</sup>Eng<sup>a</sup> Agrônoma, Mestranda em Microbiologia Agrícola - Biologia Celular e molecular, ESALQ, USP, Piracicaba - SP; <sup>4</sup>Eng<sup>o</sup> Agrônomo, Mestre em Agronomia - ICA - Instituto de Ciências Agrárias, UFRA, Belém - PA; <sup>5</sup>Eng<sup>o</sup> Agrônomo, Professor - Campus Capitão Poço, UFRA, Capitão Poço - PA

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** A citricultura passa por grandes desafios devido a competitividade existente no setor, dessa forma, a demanda por pesquisas e novas tecnologias é cada vez maior. A agricultura de precisão (AP) permite obter informações do plantio por meio da resolução espacial de imagens multiespectrais de aeronave remotamente pilotada (RPA) *in situ*. Esta técnica tem potencial uso no monitoramento do crescimento de citrus da variedade Pêra (*Citrus sinensis* L. Osbeck.) e a aplicação de insumos agrícolas. Este trabalho teve como objetivo avaliar o efeito da aplicação doses de gesso agrícola no desenvolvimento vegetativo de laranja Pêra por meio de imagens multiespectrais obtidos por técnicas de sensoriamento remoto com sensor embarcado em RPA em diferentes alturas de voo. A pesquisa foi desenvolvida, entre novembro de 2020 e julho de 2021. O experimental foi feito em DBC, em esquema fatorial 4x5x3, sendo quatro repetições e cinco tratamentos de gesso (0; 1,5; 3,0; 4,5 e 6,0 t ha<sup>-1</sup>) e três alturas de voos (80, 100 e 120 m), configurando distâncias de amostragem do solo (GSD) de 3,86, 4,74 e 5,79 cm. A coleta das imagens foi obtida através da câmera multiespectral Mapir Survey 3w em um Drone Mavic 2 PRO da DJI. Foram avaliadas a área das copas, N<sup>o</sup> de pixel, média, desvio padrão, mínimo, máximo, intervalo e variância. A dose de gesso de 0,6 t ha<sup>-1</sup> possibilitou maior ganho de área das copas, a amplitude do índice de vegetação da diferença normalizada (NDVI) e as cores foram ficando mais intensas conforme foi aumentando a altura de voo e o GSD da imagem. A altura de voo foi um fator determinante para avaliar a área das copas, uma vez que voar mais baixo proporcionou GSDs menores e por consequência melhor resolução espacial.

**PALAVRAS-CHAVE:** Resolução Espacial ; Gessagem; RPA

## USE OF MULTISPECTRAL IMAGES ON CITRUS CULTIVAR PEAR (*CITRUS SINENSIS* L. OSBECK) GROWN WITH GYPSUM APPLICATION

**ABSTRACT:** Citriculture goes through great challenges due to the existing competitiveness in the sector, thus the demand for research and new technologies is increasing. Precision agriculture (PA) allows obtaining plantation information through the spatial resolution of multispectral images from remotely piloted aircraft (RPA) *in situ*. This technique has potential use in monitoring the growth of citrus variety Pera (*Citrus sinensis* L. Osbeck.) and the application of agricultural inputs. This work aimed to evaluate the effect of gypsum application doses on the vegetative development of Pera orange through multispectral images obtained by remote sensing techniques with on-board RPA sensor at different flight heights. The research was developed between November 2020 and July 2021. The experimental was done in DBC, in a 4x5x3 factorial scheme, with four repetitions and five gypsum treatments (0; 1.5; 3.0; 4.5 and 6.0 t ha<sup>-1</sup>) and three flight heights (80, 100 and 120 m), configuring soil sampling distances (GSD) of 3.86, 4.74 and 5.79 cm. The collection of images was obtained through the Mapir Survey 3w multispectral camera on a DJI Mavic 2 PRO Drone. The canopy area, N<sup>o</sup> of pixel, mean, standard deviation, minimum, maximum, range and variance were evaluated. The gypsum dose of 0.6 t ha<sup>-1</sup> allowed greater gain in canopy area, the amplitude of the normalized difference vegetation index (NDVI) and the colors became more intense as the flight height and GSD of the image

increased. Flight height was a determining factor in evaluating canopy area, since flying lower provided smaller GSDs and therefore better spatial resolution.

**KEYWORDS:** Spatial Resolution; Gypsum plastering; RPA

**INTRODUÇÃO:** A laranja é a principal fruta cítrica cultivada no mundo, na safra 2019/20 foram produzidas 46 milhões de toneladas sendo a cadeia citrícola uma das principais atividades agrícolas do mundo, apresentado alto consumo em vários países (USDA, 2020). Contudo, existe uma forte competitividade e demanda por pesquisas e novas tecnologias (COLAÇO, 2008). Nesse contexto, a agricultura de precisão (AP) é uma imprescindível importância para o monitoramento das plantas cítricas devido à alta produtividade e variação do dossel (WHITNEY *et al.*, 1999).

A AP está associada ao uso de equipamentos tecnológicos para avaliar, ou monitorar, as condições de uma determinada parcela do terreno, e tem por objetivo o aumento de produtividade das culturas, reduzir os custos de produção e dos impactos ambientais. No entanto, para que tais objetivos sejam alcançados é importante ter o rigor no controle da aplicação dos fatores de precisão de produção (sobretudo dos produtos químicos), que deverá ser feita de acordo com a necessidade das plantas (COELHO; SILVA, 2009).

O gesso agrícola ( $\text{CaSO}_4$ ) tem sido utilizado para corrigir a acidez subsuperficial (SOBRAL; ANJOS; SILVA, 2008). Contudo, a aplicação de altas doses de gesso em regiões com alta precipitação pluviométrica, podem provocar excessiva lixiviação de bases e de micronutrientes catiônicos (RIBEIRO, GUIMARÃES, ALVAREZ, 1999). Dessa forma, objetivou-se avaliar o efeito da aplicação do gesso agrícola no desenvolvimento vegetativo de cultivar de citrus da variedade Pêra por meio de imagens multiespectrais obtidos por técnicas de sensoriamento remoto com sensor embarcado em RPA, em diferentes alturas de voo.

## MATERIAIS E MÉTODOS:

O experimento foi desenvolvido no nordeste paraense, visando avaliar a influência do gesso em um pomar de com cultivar de citrus da variedade Pêra (*Citrus sinensis* L. Osbeck) enxertada sobre limoeiro Cravo (*Citrus limonia* L. Osbeck) plantado no ano de 2018 em espaçamento 6,8 x 3,0 m, sem irrigação. Após o plantio, realizou-se o coroamento convencional para adubação de cobertura seguindo os critérios da empresa, assim como os tratos culturais, exceto a gessagem que foi aplicado de forma manual e superficial em faixas a 1 m da linha de plantio distribuídas igualmente para os dois lados da mesma em função das análises do solo. Antes da implantação do experimento, foram coletadas amostras de solo para caracterização química (Tabela 1) e física do solo (Tabela 2) da área nas profundidades de 0-20 e 20-40 cm. As análises foram realizadas de acordo com a metodologia descrita por Raij e Quaggio (1983), no laboratório de Solos da Embrapa Amazônia Oriental (Belém-PA).

TABELA 1. Caracterização química do solo da área antes da instalação do experimento.

Prof.	pH	P	K	Na	Al <sup>+3</sup>	Ca <sup>+2</sup>	Mg	H+Al	CTC		Saturação	
									Total	Efetiva	Bases	Al <sup>+3</sup>
(cm)	Água	-----mg/dm <sup>3</sup> -----			-----cmol <sub>c</sub> /dm <sup>3</sup> -----				-----%-----			
0-20	6,79	4,4	34,6	9,9	0,1	2,1	0,7	2,96	5,87	3,00	49,6	3,00
20-40	5,75	2,1	15,1	8,7	0,6	0,7	0,4	2,81	3,99	1,75	29,5	32,63

Fonte: Análises realizadas segundo metodologia descrita por Raij e Quaggio (1983), no Laboratório de Solo da Embrapa Amazônia Oriental (Belém-PA) (2020).

TABELA 2. Caracterização física do solo da área antes da instalação do experimento.

Prof. (cm)	-----Granulometria (g/kg)-----		
	Areia total	Silte	Argila
0-20	535	105	360
20-40	734	118	180

Fonte: Embrapa (2020).

As doses de gesso foram definidas a partir da análise química do solo, e em função da textura do solo (SOUSA; LOBATO, 2004). Para a camadas a ser corrigida do solo de 20-40 cm, o gesso foi aplicado em novembro de (2020), em subsuperfície e sem incorporação de gesso. O delineamento experimental foi em blocos casualizados em esquema fatorial 5x3x4, sendo cinco tratamentos com doses de gesso (0; 1,5; 3,0; 4,5 e 6,0 t ha<sup>-1</sup>), três alturas de voo (80; 100 e 120 m) com quatro blocos, onde cada parcela era composta por quatro linhas de cinco planta.

Os voos foram realizados com o Drone Mavic 2 PRO da DJI, ao qual foi acoplado a câmera Mapir Survey 3w (RGN), que captura a energia refletida dos alvos nas faixas do vermelho, verde e infravermelho próximo, possibilitando gerar os índices de vegetação.

O planejamento do voo, foi por meio do aplicativo Litchi versão 4.15.0, da VC *Technology* Ltda. Foram definidas três alturas de voo, sendo elas de 80; 100 e 120 m, com sobreposições lateral e frontal de 70 e 60 %, a respectivamente e 11 m/s<sup>-1</sup>.

As imagens foram processadas no *Software Agisoft Metashape* 1.7.2, versão teste, e o ortomosaico de cada voo foi exportado para o *Software QGIS* versão 3.16 para extração do Índice De Vegetação Por Diferença Normalizada (NDVI) calculado pela equação 1:

$$NDVI = \frac{NIR - R}{NIR + R}$$

Eq. (13)

Em que:

**R** = reflectância proveniente do canal vermelho

**NIR** = é a reflectância proveniente do canal do infravermelho próximo

Para a extração dos números digitais, foram criados 21 shapefile, sendo o primeiro fazendo delimitação das parcelas, dentro de cada parcela as plantas avaliadas foram vetorizadas para posterior extração das áreas de suas copas por meio da ferramenta Field Calculator do *Software QGIS* 3.16.

Os dados referentes aos valores de NDVI foram submetidos à análise descritiva (Área, N ° de Pixel, Média, Desvio Padrão, Mínimo, Máximo, Intervalo e Variância) pela ferramenta Zonal Statistic do *Software Qgis* 3.16 e em seguida foi realizada a correlação linear de Pearson (r), com o uso do *Software R*. As variáveis área m<sup>2</sup>, n° de pixel, média, desvio padrão, mínimo, máximo, intervalo e variância, foram submetidas à análise de variância para cada altura de voo. E em seguida, foram comparadas as médias das variáveis em função das doses de gesso aplicadas pelo teste de Tukey a 5 % e a 1 %.

## RESULTADOS E DISCUSSÃO:

Foi realizada a contagem do número de pixels para cada um dos cinco tratamentos nas três alturas de voo (80, 100 e 120 m), apresentando valores médios de 1764,7083, 2519,4348, 2002,0000, 1944,5652 e 1765,4783 no voo de 80 m, 907,0000, 1116,1739, 1056,5217, 1058,0000 e 981,4348 no voo de 100 m, 678,4583, 818,3913, 750,0870, 749,7826 e 676,0000 no voo de 120 m, dos quais foram extraídos os valores do NDVI.

As médias dos valores de NDVI foram de 0,3182, 0,3146, 0,3150, 0,3207 e 0,3091 para o voo de 80 m nos cinco tratamentos avaliados, 0,3190, 0,3067, 0,3154, 0,3098 e 0,2963, no voo de 100 m e 0,3093, 0,3056, 0,3083, 0,3090 e 0,3019 no voo de 120 m para o NDVI (Tabela 3).

Os baixos valores de variância e desvio padrão (Tabela 3) demonstram que os valores estão uniformemente distribuídos e com margem de erro próximas aos valores das médias. Os valores máximo e mínimo de refletância dos pixels demonstram que os dados apresentam valores com pequena variação, o que significa que para vetorização das copas das laranjeiras foram selecionadas apenas pixels que representam as plantas avaliadas.

As copas das plantas apresentaram as seguintes áreas, nas três alturas de voos para cada tratamento: 2,6247, 3,8324, 2,8912, 2,8931 e 2,6279 m<sup>2</sup>, para o voo de 80 m, 2,0320, 2,5074, 2,3700, 2,3737 e 2,2022 m<sup>2</sup> para o voo de 100 m, 2,2726, 2,7442, 2,5173, 2,5127 e 2,2683 m<sup>2</sup> para o voo de 120 m. O tratamento 2 (0,6 t ha<sup>-1</sup>) obteve as maiores médias por área das copas nas três alturas de voos (Tabela 3).

**TABELA 3. Estatística descritiva respectiva aos valores de NDVI extraídos da área das copas das laranjeiras analisadas para os tratamentos (0; 0,6; 1,2; 1,8 e 2,4 t ha<sup>-1</sup> de gesso, nas alturas de voo de 80, 100 e 120 m respectivamente. Descriptive statistics respective to the NDVI values extracted from the canopy area of the orange trees analyzed for the treatments (0; 0.6; 1.2; 1.8 and 2.4 t ha<sup>-1</sup> of gypsum, at flight heights of 80, 100 and 120 m respectively.**

NDVI					
Avaliação	Trat 1	Trat 2	Trat 3	Trat 4	Trat 5
Área (m <sup>2</sup> )	2,6247	3,8324	2,8912	2,8931	2,6279
Nº de pixel	1764,7083	2519,4348	2002,0000	1944,5652	1765,4783
Média	0,3182	0,3146	0,3150	0,3207	0,3091
Desvio Padrão	0,0230	0,0266	0,0224	0,0259	0,0283
Mínimo	0,1940	0,1741	0,1985	0,1850	0,1677
Máximo	0,3724	0,3807	0,3704	0,3859	0,3752
Intervalo	0,1784	0,2066	0,1718	0,2009	0,2075
Variância	0,0006	0,0008	0,0005	0,0007	0,0009
p-Valor (95.0%)	0,0067	0,0042	0,0051	0,0056	0,0055
NDVI					
Avaliação	Trat 1	Trat 2	Trat 3	Trat 4	Trat 5
Área (m <sup>2</sup> )	2,0320	2,5074	2,3700	2,3737	2,2022
Nº de pixel	907,0000	1116,1739	1056,5217	1058,0000	981,4348
Média	0,3190	0,3067	0,3154	0,3098	0,2963
Desvio Padrão	0,0263	0,0190	0,0266	0,0247	0,0202
Mínimo	0,1902	0,2164	0,1939	0,1818	0,1999



Máximo	0,3709	0,3498	0,3689	0,3612	0,3397
Intervalo	0,1807	0,1334	0,1750	0,1794	0,1398
Variância	0,0007	0,0004	0,0008	0,0007	0,0004
p-Valor (95.0%)	0,0042	0,0039	0,0045	0,0074	0,0071
<b>NDVI</b>					
Avaliação	<b>Trat 1</b>	<b>Trat 2</b>	<b>Trat 3</b>	<b>Trat 4</b>	<b>Trat 5</b>
Área (m <sup>2</sup> )	2,2726	2,7442	2,5173	2,5127	2,2683
Nº de pixel	678,4583	818,3913	750,0870	749,7826	676,0000
Média	0,3093	0,3056	0,3083	0,3090	0,3019
Desvio Padrão	0,0256	0,0214	0,0224	0,0205	0,0228
Mínimo	0,1969	0,2049	0,2158	0,2173	0,2077
Máximo	0,3596	0,3509	0,3580	0,3529	0,3482
Intervalo	0,1627	0,1460	0,1422	0,1357	0,1405
Variância	0,0007	0,0005	0,0005	0,0005	0,0006
p-Valor (95.0%)	0,0040	0,0038	0,0049	0,0040	0,0048

Ao realizar a análise visual do NDVI nas diferentes alturas de voo (Figura 1) nota-se que há uma diferença entre as cores, conforme foi aumentando a altura de voo e o GSD da imagem. Corroborando a isso, ao olhar os intervalos dos números do NDVI, é possível observar uma pequena mudança na amplitude do índice nas diferentes alturas de voo, de forma que os números foram diminuindo conforme a altura de voo foi aumentando, e proporcionou uma adequada distinção visual das copas para as alturas de voo (Figura 1).



**FIGURA 1. Comparativo entre as ortofotos de NDVI para as alturas de 80, 100 e 120 m. Comparison between NDVI orthophotos for the heights of 80, 100 and 120 m.**

As diferentes doses de gesso foram significantes (p-valor < 0,01), ou seja, é um fator que faz diferença na área das copas das laranjeiras em solos ácidos na subsuperfície (Tabela 2). Vicensi *et al.*, (2020) assinalam que o gesso agrícola pode melhorar a eficiência de absorção de alguns nutrientes pelo sistema radicular. Dessa forma, a sua aplicação contribui para o aumento da área das copas das cultivares citrus da variedade Pêra.

A interação entre a altura de voo e as doses de gesso foi significativa (p-valor < 0,01). A altura de voo influencia no GSD da imagem, logo as relações entre as doses de gesso foram mais bem evidenciadas. Batista (2017) descreve que o GSD está diretamente relacionado à resolução espacial da imagem, por tratar-se da representação do pixel da imagem em unidades do terreno. Assim em GSDs maiores o nível de detalhamento das imagens é menor, dessa forma, o GSD está correlacionado à altura de voo.

O fator doses de gesso e área das copas também mostrou interação significativa (p-valor < 0,01). Assim, a adição de doses de gesso proporcionou incremento na produção das áreas das copas das cultivares de citrus da variedade Pêra, refletindo no aumento da área das copas. A variável altura de voo e área das copas também foi significativo (p-valor < 0,01), indicando que a altura de voo foi um fator primordial na delimitação da área das copas.

Tabela 2. Médias do NDVI, em função das doses de Gesso, correlacionado com as áreas das copas nas três alturas de voo de 80, 100 e 120 m, para a respectiva avaliação. **Mean NDVI, as a function of Gypsum doses, correlated with canopy areas at the three flight heights of 80, 100 and 120 m, for the respective evaluation.**

Fontes de variação	GL	NDVI	Área das copas
Doses de gesso (D)	4	12,49**	17,49**
Altura de voo (AV)	2	10,26**	53,49**
D x AV	8	2,05*	3,82**
Bloco	3	11,81**	36,04**
CV (%)		3,62	19,01

\* p-valor menor que 5%; \*\* p-valor menor que 1%; ns sem significância;

As médias do NDVI observadas nos tratamentos referentes ao voo de 80 m apresentaram diferença significativa entre as doses de 1,8 e 2,4 t há<sup>-1</sup> de gesso aplicadas, e as doses 0, 1,5, 3 e 4,5 t.ha<sup>-1</sup> não diferenciando entre si, assim como as de 0, 1,5, 3 e 6 t.ha<sup>-1</sup> (Tabela 3) . Para o voo de 100 m apresentou diferença significativa apenas a dose de 6 t ha<sup>-1</sup>, diferente do voo de 120 m que não apresentou diferença significativa em nenhuma das doses testadas.

TABELA 3. Comparação de médias do NDVI, em função das doses de Gesso e alturas de voo de 80, 100 e 120 m. **Comparison of NDVI averages as a function of Gypsum doses and flight heights of 80, 100 and 120 m.**

Doses de gesso (t ha <sup>-1</sup> )	Altura do voo					
	80		100		120	
0	0,31	abA±0,01	0,31	aA±0,01	0,31	aA±0,01
0,6	0,31	abA±0,01	0,30	aA±0,01	0,30	aA±0,01
1,2	0,31	abA±0,01	0,31	aA±0,01	0,31	aA±0,01
1,8	0,32	aA±0,01	0,30	aB±0,01	0,31	aB±0,01
2,4	0,30	bA±0,01	0,29	bA±0,01	0,30	aA±0,01

Letras minúsculas comparam colunas; Letras maiúsculas comparam linhas.

Letras diferentes denotam diferenças significativas entre médias comparados no mesmo dia de avaliação. \* p-valor menor que 5%; \*\* p-valor menor que 1%; ns sem significância;

As alturas de voo apresentaram diferenças significativas somente para a dose de 4,5 t ha<sup>-1</sup> de gesso, diferenciando entre si nas alturas de 80 e 100 e 80 e 120 m.

A variável área das copas apresentou interação significativa entre as doses de gesso aplicadas, em que a maior média da variável foi observada na dose de gesso de 0,6 t ha<sup>-1</sup> no voo de 80 m. As demais doses não diferiram entre os tratamentos para os voos de 100 e 120 m, também foi possível observar diferença entre as alturas de voos (Tabela 3).

Tabela 4. Comparação de médias de área da copa das plantas, doses de Gesso, Alturas de voo. **Comparison of means of plant canopy area, Gypsum doses, Flight heights.**

Doses de gesso (t ha <sup>-1</sup> )	Altura do voo					
	80		100		120	
0 t	2,62	bA±0,37	2,00	bB±0,49	2,28	aB±0,49
0,6	3,75	aA±0,71	3,39	aB±0,61	2,62	aB±0,43
1,2	2,83	bA±0,66	2,37	abB±0,58	2,53	aB±0,71
1,8	2,84	bA±0,54	2,54	abB±0,69	2,52	aB±0,65
2,4	2,73	bA±0,44	2,28	abB±0,52	2,34	aB±0,52

Letras minúsculas comparam colunas; Letras maiúsculas comparam linhas.

O maior incremento de área das copas na dose 0,6 t ha<sup>-1</sup> pode ser explicado pelos efeitos exercidos pelo gesso no favorecimento do crescimento radicular (CAIRES *et al.*, 2003).

A variável altura de voo apresentou interação significativa entre si, uma vez que proporcionou adequada discriminação visual na delimitação de área da copa das plantas entre as alturas de voo. A melhor altura de voo para fazer a delimitação das copas foi de 80 m, as demais alturas não diferiram entre si. Esse fato pode ter ocorrido devido menores alturas de voo proporcionarem uma maior resolução espacial da imagem. Ou seja, haverá uma maior quantidade de pixel, o que irá influenciar diretamente na qualidade da imagem e, com isso, resultará em uma maior exatidão na delimitação das copas. De acordo com Barbosa Júnior (2021) ao aumentar o tamanho do pixel ocorre redução na resolução das imagens. Zhang *et al.* (2020) observaram que quando o GSD  $\geq 5,73$  cm gera informações imprecisas e grande heterogeneidade dentro do pixel.

Para a altura de 80 m, quando o sensor foi utilizado no voo mais próximo ao solo, ele produziu um GSD menor, por conta disso, precisou de mais fotos para cobrir a mesma área em um maior tempo de voo da RPA em comparação às alturas de 100 e 120 m, que produziram um GSD maior. Corroborando com Silva Neto (2015), o qual enfatiza que o tamanho do GSD de um aerolevanteamento é inversamente proporcional ao nível de detalhamento atingido. Todavia, GSDs menores demandam maior quantidade de imagens, maior tempo de voo e maior capacidade de processamento, para mapear uma área de mesmas dimensões, do que um GSD maior. Embora ainda não houvesse trabalhos que avaliam o gesso na cultura dos citros por imageamento multiespectrais no polo citrícola da região nordeste paraense, a aplicabilidade desta técnica segue os princípios da AP, tornando a mesma por sensor favorável na análise do desenvolvimento vegetativo da cultura

**CONCLUSÃO:** A a melhor dose de gesso foi a 0,6 t há<sup>-1</sup> a para a área das copas das cultivares de citrus da variedade Pêra. Conclui-se também que a altura de voo de 80 m mostrou-se mais adequada para delimitar as copas das plantas por meio de imagens multiespectrais obtidas por RPAS. Portanto o uso de imagens multiespectrais apresenta-se como ferramenta consistente na discriminação do NDVI para a cultura de citros, sendo uma área que merece maiores estudos ao longo do ciclo da cultura e em ambientes diversos.

## REFERÊNCIAS

BACKES, C. C. *et al.* Taxa de cobertura verde e exportação de macronutrientes pelo capim Marandu em função da aplicação de gesso. **Archivos de Zootecnia**, Córdoba, v. 67. n. 258. 2018. p. 8.

BARBOSA JÚNIOR, M. R. Mapeamento de falhas em cana-de-açúcar por imagens de veículo aéreo não tripulado. ORIENTADOR: Cristiano Zerbato. 2021. 51 f. **Dissertação de mestrado apresentada à Faculdade de Ciências Agrárias e Veterinárias – UNESP** (obtenção do título de mestre em Agronomia). Jaboticabal, SP, 2021.

- BATISTA, F. L. Plano de voo e Aquisição de Imagens. Disponível em: <https://www.austertecnologia.com/single-post/2017/05/27/plano-de-voo-e-aquisi%C3%A7%C3%A3o-de-imagens>. Acesso em: 24 jul. 2021.
- CAIRES, E.F. *et al.* Alterações químicas do solo e resposta da soja ao calcário e gesso aplicados na implantação do sistema de plantio direto. **Revista Brasileira de Ciência Solo**, v.27, p.275-286, 2003.
- COELHO, J. P. C.; SILVA, J. R. M. Agricultura de Precisão. 1. ed. Lisboa: **Gazela**, 2009. 141 p.
- COLAÇO, A. F. Agricultura de Precisão e Colheita Mecanizada em Citros. Orientador. José Paulo Molin. Disciplina. 2008. 41 f. Estágio Profissionalizante em Engenharia Agrônômica – **Escola Superior de Agricultura “Luiz de Queiroz”, Piracicaba, SP**, 2008.
- ERNANI, P. R.; RIBEIRO, M. S.; BAYER, C. Modificações químicas em solos ácidos ocasionadas pelo método de aplicação de corretivos da acidez e de gesso agrícola. **Scientia Agrícola**, Piracicaba, v.58, p.825-831, 2001.
- RAIJ, B. V. Gesso na Agricultura. *In*: ABDALLA, S. R. S.; PROCHNOW, L. I.; FANCELLI, A. L. Simpósio discute como utilizar insumos e recursos para otimizar a insumos e recursos para otimizar a produtividade do milho produtividade do milho. **International Plant Nutrition Institute. Informações Agronômicas**. Piracicaba-SP, n. 122, jun. 2008. p. 25.
- RIBEIRO, A. C.; GUIMARÃES, P. T. G.; ALVAREZ, V. V. H. Recomendações para o uso de corretivos e fertilizantes em Minas Gerais: 5ª aproximação. 20. ed. Eds. **Viçosa**: 1999. 323 p.
- SANTOS, A. A importância da citricultura nacional. Confederação da Agricultura e Pecuária do Brasil. Disponível em: <https://www.cnabrazil.org.br/noticias/a-importancia-da-citricultura-nacional>. 2019. Acesso em: 27 fev. 2021.
- SOUZA, D. M. G.; LOBATO, E. **Cerrado: correção do solo e adubação**. 2. ed. Brasília: Embrapa Cerrados, 2004, 416 p.
- SILVA NETO, Manoel (Ed.). Planejamento de Voo e GSD. 2015. Disponível em: <https://blog.droneng.com.br/planejamento-de-voo-para-grandes-areas/>. Acesso em: 1 set. 2021.
- SOBRAL, L. F.; ANJOS, J. L.; SILVA, J. U. B. Calagem e adubação da laranjeira no estado de Sergipe, 1ª ed. **Embrapa, Aracaju**, n. 54, ago. 2008, Circular Técnica, p. 6.
- UNITED STATES DEPARTMENT OF AGRICULTURE. USDA. Foreign Agricultural Service. Citrus: **World Markets and trade**. Nov. 2019. Disponível em: <https://www.fgov/data/citrus-world-markets-and-trade>. Acesso em: 23 mar. 2021.
- VICENSI, M. *et al.* Do rates and splitting of phosphogypsum applications influence the soil and annual crops in a no-tillage system?. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 40, set. 2015. p. 17.
- WHITNEY, J. D. *et al.* Precision farming applications in Florida citrus. **Applied Engineering in Agriculture**, 1999. p. 399-403.
- ZHANG, J. *et al.* Assessing the Effect of Real Spatial Resolution of In Situ UAV Multispectral Images on Seedling Rapeseed Growth Monitoring. **Remote Sens**, Basel, v. 12, n. 7, abr. 2020. p. 18

# PREDIÇÃO DA PRODUTIVIDADE DE SOJA VIA ÍNDICES DE VEGETAÇÃO

Natasha Costa Penatti<sup>1</sup>; Aline Edlaine de Medeiros<sup>2</sup>; ROSEANNE LARISSA FABENI<sup>3</sup>; JULIANO DONINI DA SILVA<sup>4</sup>

<sup>1</sup>Bióloga, Especialista em Sensoriamento Remoto - FarmGO, Av. Bento Munhoz da Rocha Neto, 632 - Zona 7, Maringá - PR. nat.bio@gmail.com / (11) 9 6433-2248; <sup>2</sup>Estatística, Pesquisadora - FarmGO, Av. Bento Munhoz da Rocha Neto, 632 - Zona 7, Maringá - PR; <sup>3</sup>Engenheira agrônoma, Engenheira agrônoma - FarmGO, Av. Bento Munhoz da Rocha Neto, 632 - Zona 7, Maringá - PR; <sup>4</sup>Cientista da Computação, Cientista de Dados - FarmGO, Av. Bento Munhoz da Rocha Neto, 632 - Zona 7, Maringá - PR

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Para garantir segurança alimentar, sustentar os mercados agrícolas e direcionar políticas governamentais é crucial obter estimativas precisas da produtividade antes da colheita. Nas últimas décadas, o sensoriamento remoto tem se mostrado uma ferramenta útil para monitorar as culturas e estimar seu rendimento. Neste contexto, este estudo investigou a relação entre os índices de vegetação (IVs) e a produtividade de soja em 18 talhões localizados no município de Tapes – RS ao longo de todo o ciclo da cultura e avaliou o melhor período para estimar a produtividade com base nos IVs (NDVI, NDRE e GNDVI). A relação foi descrita através do modelo de regressão linear simples e múltipla entre os valores dos IVs ao longo da safra e seu respectivo mapa de produtividade, cuja adequação foi validada via análise de resíduos usual. Os estádios fenológicos R4, R5 e R6 foram aqueles em que os valores observados dos IVs melhor descreveram o comportamento da produtividade em cada talhão. Ainda que outros dados, como as variáveis agrometeorológicas, notoriamente auxiliem na compreensão da produtividade, os resultados obtidos condizem com a literatura já existente, evidenciando o quanto os IVs podem auxiliar na captura das principais tendências de produtividade da soja, evidenciando a importância dessas informações no monitoramento agrícola e na agricultura de precisão.

**PALAVRAS-CHAVE:** dias após semeadura; regressão; sentinel-2

## SOYBEAN YIELD PREDICTION USING VEGETATION INDICES

**ABSTRACT:** To ensure food security, sustain agricultural markets and direct government policies it is crucial to obtain accurate estimates of productivity before harvest. In recent decades, remote sensing has proved to be a useful tool to monitor crops and estimate their yield. In this context, this study investigated the relationship between vegetation indices (VIs) and soybean productivity in 18 plots located in the municipality of Tapes - RS throughout the entire crop cycle, as well as evaluated the best period to estimate productivity based on the VIs (NDVI, NDRE, and GNDVI). The relationship was described through the simple and multiple linear regression models between the values of VIs throughout the season and their respective yield map, whose adequacy was validated via the usual residual analysis. The phenological growth stages R4, R5, and R6 were those in which the observed values of VIs best described the behavior of productivity in each stand. Although other data, such as agrometeorological variables, notoriously help in the understanding of productivity, the results obtained are consistent with the existing literature, showing how much VIs can help capturing the main trends in soybean productivity, evidencing the importance of these data in agricultural monitoring and precision agriculture.

**KEYWORDS:** days after sowing; regression; sentinel-2

**INTRODUÇÃO:** Estudos recentes demonstram que a demanda global total de alimentos aumentará de 35% a 56% entre 2010 e 2050 (VAN DIJK et al., 2021). Para suprir demandas futuras de segurança alimentar e sustentabilidade, a produção agrícola mundial deve crescer substancialmente (FOLEY et al., 2011). Assim, o aumento do rendimento das culturas com o uso otimizado de insumos é um desafio inevitável. Neste contexto, a agricultura de precisão (AP) se mostra crucial para enfrentar os desafios da produção agrícola, auxiliando na tomada de decisões e promovendo melhorias na gestão dos sistemas de produção. Estudos demonstram que a

AP pode aumentar a produtividade global das lavouras em até 67%, reduzindo ainda os custos e os impactos ambientais negativos (ROSEGRANT et al., 2014).

A produtividade varia ao longo do tempo de acordo com diversos fatores como: condições climáticas (déficit ou excesso hídrico, temperatura e radiação solar), manejos do solo ou da cultura, pragas e doenças, entre outros. Além disso, a produtividade tende a apresentar variabilidade dentro de uma mesma região, tanto temporal (diferença entre as safras), quanto espacial, que pode estar relacionada às características intrínsecas das áreas, como relevo e tipo de solo.

Métodos de sensoriamento remoto (SR) para monitoramento de culturas e estimativa de produtividade foram aprimorados nas últimas décadas devido ao seu potencial de fornecer informações precisas e oportunas durante o período de crescimento da cultura, minimizando perdas e aumentando a eficácia produtiva. Entre eles estão os índices de vegetação (IVs), algoritmos utilizados na avaliação da cobertura vegetal, vigor e dinâmica de crescimento, estado nutricional, entre outras aplicações (XUE e SU, 2017), tornando-os uma ferramenta crucial no monitoramento agrícola, na previsão e estimativa de produtividade das culturas. Recentemente, diversos trabalhos relataram uma correlação entre IVs e produtividade em diferentes culturas (LAMBERT et al., 2018; EVANS e SHEN, 2021; NAZIR et al., 2021; GARCÍA-MARTÍNEZ et al., 2020; ZHAO et al., 2020; CHAMNAN, 2021; SCHWALBERT et al., 2020), mas poucos avaliaram os impactos dos estádios fenológicos na estimativa de produtividade (NAZIR et al., 2021). Além disso, estudos que fornecem informações em escala de campo ainda são incipientes e podem auxiliar na AP.

Considerando a importância da soja no Brasil, maior produtor e exportador de soja no mundo, e seu impacto sobre a economia global, este estudo teve como objetivo geral avaliar a relação entre IVs derivados de imagens Sentinel-2 em diferentes estádios fenológicos da cultura da soja e sua produtividade em 18 talhões na região de Tapes, Rio Grande do Sul, Brasil.

**MATERIAIS E MÉTODOS:** Para o presente estudo foram selecionados 18 talhões localizados no município de Tapes, no litoral da Lagoa dos Patos, Rio Grande do Sul (Figura 1). O município possui uma área territorial de 806,30 km<sup>2</sup> e população de 17.390 habitantes (IBGE, 2016). O clima da região é subtropical úmido (tipo Cfa) segundo o sistema de Köppen, com temperatura média variando entre 16 e 20°C e precipitação pluviométrica anual entre 1.000 e 1.500mm (NIMER, 1977 apud BECKER et al., 2007).

As lavouras de soja estudadas foram cultivadas no ano agrícola 2020/2021 com plantio entre fim de outubro e início de novembro e colheita entre meados de março e início de abril. Foram plantados os cultivares: NS 6601 IPRO, DM 5958 RSF IPRO e MONSOY 5947 IPRO. A produtividade média das áreas foi de 4,16 t/ha e variou de 3,12 t/ha a 5,27 t/ha. Todos os talhões foram colhidos de forma mecanizada por meio de uma máquina colhedora equipada com monitor de produtividade e receptor GNSS. Os dados brutos de produtividade obtidos para cada área durante a colheita foram pré-processados antes de correlacioná-los com as imagens de satélite. Foram usados os dados da produtividade de grãos de soja corrigidos a 13% de umidade. Estes dados foram ainda filtrados para retirada dos valores discrepantes (*outliers*) e posteriormente interpolados para geração dos mapas de produtividade.

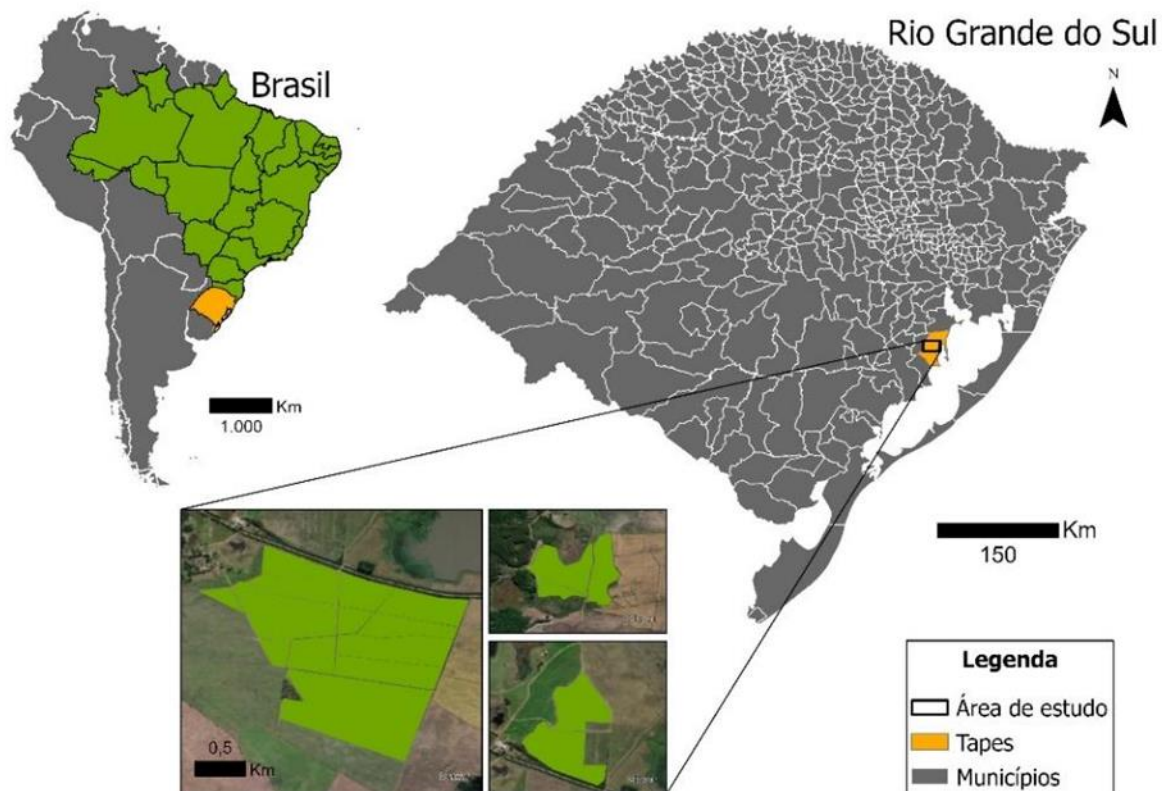


FIGURA 1. Localização das áreas de estudo no município de Tapes, Rio Grande do Sul.

Séries temporais de índices de vegetação (NDVI, GNDVI e NDRE) (Tabela 1) foram adquiridas a partir de imagens Sentinel-2 sem nuvem, com nível de correção L2A para toda a safra, desde a semeadura até o período de colheita, para cada um dos 18 talhões estudados. Para evitar a contaminação do entorno dos talhões e a incorporação de pixels mistos, foi aplicado um buffer interno de 10 m. Isso é importante para manter o sinal da cultura puro, evitando a incorporação de sinais espectrais de estradas, árvores e outros alvos que não são de interesse. Essas imagens foram processadas na plataforma Google Earth Engine (GEE) utilizando rotina em *JavaScript*. Todos os dados foram reamostrados para 10 metros (m) para possibilitar a comparação entre os índices e os mapas de produtividade.

TABELA 1. Índices de vegetação obtidos a partir das imagens Sentinel-2. NIR, Red, Green e RedEdge1 são os valores de refletância para o infravermelho próximo, vermelho, verde e vermelho limítrofe 1, respectivamente.

Índice	Equação	Referência
Normalized Difference Vegetation Index (NDVI)	$NDVI = (NIR - Red)/(NIR + Red)$	Rouse et al. (1973)
Green Normalized Difference Vegetation Index (GNDVI)	$GNDVI = (NIR - Green)/(NIR + Green)$	Gitelson et al. (1996)
Normalized Difference Red-Edge (NDRE)	$NDRE = (NIR - RedEdge1)/(NIR + RedEdge1)$	Gitelson e Merzlyak (1994)

A modelagem de dados foi desenvolvida no software R Core Team (2022), versão 4.1.1, onde foi ajustado o modelo de regressão linear múltiplo para cada um dos IVs, dado por:

$$Y_i = \alpha_0 + \sum_{j=1}^n \alpha_j * X_{ij} \quad (1)$$

Cada  $X_{ij}$  corresponde as observações da variável  $X$ (IV) de tamanho  $i$  na covariável  $j$  representando os dias após semeadura (DAS) (RENCHEER et al., 2008). Foi ajustado também um modelo de regressão linear simples que é análogo à expressão (1) restrita a uma única covariável  $X_{ij}$ . Tal ajuste foi realizado no intuito de exprimir a relação existente entre os IVs e a produtividade. A escolha desta metodologia deve-se a simplicidade na aplicação e comparação entre os modelos ajustados, embora um modelo para cada talhão poderia retornar em estimativas mais precisas, este processo seria oneroso e de difícil escalabilidade como um produto no setor agrícola.

Considerando a diversidade de imagens disponíveis para cada uma das 18 áreas sob análise, foi adotado o procedimento chamado de *stepwise* (VENABLES e RIPLEY, 2013) para relacionar a produtividade nas diferentes datas aos três índices de vegetação. Este método utiliza o critério da informação de Akaike (AIC) para incluir ou remover covariáveis no modelo de regressão, sendo que modelos com menores valores de AIC são considerados melhores (AKAIKE, 1974).

Para comparar se as medidas de AIC e coeficiente de determinação dos modelos multivariado e univariado eram similares, indicando que ambos os modelos descrevem a produtividade de modo análogo, utilizou-se do teste t pareado, cuja hipótese nula é de que a diferenças entre as médias são nulas contra a hipótese alternativa de que tais diferenças diferem de zero. Tal teste baseia-se na estatística *t-student* dada por:

$$t = \frac{\bar{d}}{\frac{S_D}{\sqrt{n}}} \sim t_{n-1} \quad (2)$$

com  $n - 1$  graus de liberdade e  $n$  representando o tamanho da amostra,  $S_D$  o desvio padrão e  $\bar{d}$  a média amostral (Daniel, 2018).

A adequação dos modelos foi constatada via análise dos resíduos simples e por meio do gráfico do tipo *q-qplot*. Observou-se ainda os valores do AIC, da raiz do erro quadrático médio (RMSE) e do coeficiente de determinação ( $R^2$ ), visando compreender se foram satisfeitas as condições de normalidade dos resíduos e se eles tendem a zero.

**RESULTADOS E DISCUSSÃO:** Devido à alta correlação observada entre os IVs em cada data e a produtividade, investigou-se a capacidade de cada um dos índices GNDVI, NDVI e NDRE observados ao longo da safra em prever o valor da produtividade. Os modelos de regressão múltiplos, selecionados via *stepwise*, foram capazes de prever a produtividade com elevados coeficientes de determinação. O valor mediano destes coeficientes foi de 0,98 para todos os índices observados, como pode-se verificar na Figura 2, por meio do gráfico do tipo *boxplot*.




Figura 2. Coeficiente de determinação de cada índice de vegetação nos modelos de regressão multivariados.



Foi aplicado o teste t pareado com relação aos coeficientes de determinação e AIC encontrados para cada IV, ao nível de significância  $\alpha = 0,01$  (99% de confiança), e constatou-se que os índices não diferem em explicar a produtividade (valores-p > 0,01).

Embora, os modelos de regressão linear múltipla ajustados sejam eficazes em explicar a produtividade, em uma safra em curso nem todas as datas do modelo estarão disponíveis, pois representam observações futuras ou ainda, podem estar indisponíveis devido à presença de nuvens e a data de imageamento do sensor. Assim, buscou-se investigar a existência de um estágio fenológico mais viável para descrever a produtividade sem perder a capacidade explicativa obtida na regressão linear múltipla.

Na investigação de um período ótimo para prever a produtividade foram ajustados modelos univariados para cada talhão e datas disponíveis. Dentre estes modelos, selecionou-se aqueles com maior capacidade explicativa (Figura 3). Nota-se que o valor mediano de tais coeficientes foi de 0,965 para o GNDVI, 0,97 para o NDVI e 0,96 para o NDRE.

O RMSE nas áreas manteve-se com valores entre 0,15 e 0,54 t/ha para o NDVI, entre 0,14 e 0,55 t/ha para o GNDVI, e 0,14 e 0,58 t/ha para o NDRE. Considerando que o valor médio da produtividade foi de 4,16 t/ha, e o RMSE encontra-se na mesma escala de dados, em média o valor de erro representa valores entre 3% e 14% da produtividade média.




Figura 3. Coeficientes de determinação de cada índice de vegetação nos modelos de regressão univariados.

Apesar da leve variação mediana dos coeficientes analisados na Figura 3, de acordo com o teste t pareado não houve diferença significativa entre a capacidade de explicação e AIC de cada IV (valores-p > 0,01), nem entre os modelos multivariados e univariados (valores-p > 0,01) no que concerne a capacidade explicativa. Com relação aos valores de AIC, os valores obtidos no modelo univariado são significativamente maiores (valores-p < 0,01) que no modelo multivariado, o que se deve ao critério de seleção *stepwise* aplicado ao modelo multivariado. Todavia, a capacidade de explicação não decaiu e nem a boa adequação do modelo, indicando que existem datas ao longo do ciclo capazes de prever satisfatoriamente a produtividade.

Apesar dos índices não apresentarem diferença significativa nos modelos de regressão avaliados, deve-se levar em consideração que o NDVI, apesar de utilizado amplamente com eficiência nas mais diversas abordagens, pode apresentar alguns fatores limitantes, como a sua saturação quando o índice de área foliar é alto, o que pode ocorrer em estágios de crescimento mais avançados de culturas agrícolas, e ainda na presença de solos escuros, que podem gerar um aumento no valor desse índice, especialmente em dosséis com níveis médios de cobertura vegetal (HUETE et al, 1985). Esses fatores não devem ocorrer no GNDVI e no NDRE, o que deve ser considerado ao se escolher o índice de vegetação a ser utilizado.

GITELSON et al. (1996) propuseram o GNDVI com objetivo de superar esses problemas observados no NDVI, o que foi confirmado por GIANELLE et al. (2009), que demonstraram que esse índice pode ser um bom indicador de uma série de preditores de produtividade da vegetação. O NDRE, por sua vez, é capaz de medir mais a fundo o dossel vegetal, além de ser menos propenso a saturação, podendo fornecer melhor resposta para culturas permanentes ou em estágio posterior (SAMPAIO et al, 2021).

Visto que os modelos univariados descreveram apropriadamente a relação entre os IVs e a produtividade, buscou-se definir as datas em que esta relação é melhor capturada pelos modelos. A Figura 4 apresenta o dia após semeadura (DAS) médio e mediano em que a capacidade explicativa de cada IV e modelo foi a maior observada e seus respectivos intervalos de confiança (IC), que representam o período ótimo para prever a produtividade para a área de estudo através dos índices de vegetação. Salienta-se que os valores contidos nos intervalos de confiança são igualmente prováveis em relação ao ponto médio/mediano observado.

O NDVI apresentou o valor médio no DAS 83 com IC entre 77 e 88 dias após a semeadura, no GNDVI o valor médio ocorreu no DAS 87 com IC entre 81 e 92 dias após semeadura e no NDRE o valor médio se deu no DAS 91 com IC entre os dias 86 e 97 após a semeadura. Tais valores são próximos dos valores medianos indicando que a distribuição de tais dados não é fortemente assimétrica. Os períodos encontrados são compatíveis com os estádios fenológicos entre R4 e R6 - a depender da duração do ciclo e do índice utilizado - sendo este o melhor intervalo para predição da produtividade na área de estudo.




Figura 4. Média e mediana do dia após a semeadura com maior coeficiente de determinação e respectivos intervalos de confiança por índice de vegetação.

Como nas áreas estudadas foram utilizados cultivares com ciclos distintos, é importante ressaltar que os períodos ótimos podem estar deslocados na série temporal. Para áreas com ciclos mais longos (em torno de 160 dias) é possível ter melhores estimativas da produtividade aproximadamente na metade da safra, entre R4 e R5, já para cultivares com ciclos mais curtos (entre 125 e 149 dias) tais estimativas ocorrem um pouco mais à frente, deslocadas para os estágios R5 e R6. Tais estágios foram identificados cruzando os períodos ótimos acima identificados com o ciclo de cada um dos talhões e seus respectivos estádios fenológicos.

Os dados apresentados condizem com os encontrados na literatura. SHAMMI e MENG (2021) utilizando dados MODIS foram capazes de prever a produtividade de soja a partir dos 70 dias de emergência utilizando NDVI e EVI, sendo que os índices de crescimento de 70 e 85 dias foram os que melhor descreveram a produtividade da soja. MA et al. (2001) por sua vez, encontraram uma maior correlação entre rendimento de soja e refletância em R4 e R5 do que no estágio fenológico R2.

WIEGAND et al. (1986) demonstraram que as relações entre os rendimentos das culturas e os IVs são mais fortes durante o estágio inicial de enchimento de grãos (R5), uma vez que os tecidos senescentes ou fotossinteticamente inativos que se desenvolvem após esse estágio podem degradar a relação. No presente estudo, diferentemente do encontrado por esses autores, até o estágio R6 foram percebidos bons resultados,

mas a relação começa a se degradar após esse estágio, o que deve estar relacionados ao início da senescência da cultura.

SCHWALBERT et al. (2020) combinaram dados meteorológicos com imagens de satélite para diversos municípios do Rio Grande do Sul e encontraram uma diminuição na precisão do modelo de produtividade antecipando a data de previsão da produtividade antes da colheita de soja, mas determinaram que esta poderia ser prevista até aproximadamente 70 dias antes da colheita com razoável precisão.

A Figura 5 apresenta o histograma de resíduos e o gráfico dos quantis teóricos versus os quantis amostrais para cada observação contida na imagem de um dos talhões observados e considerando o GNDVI. Nota-se que os resíduos se concentram em torno de zero, além disso, a maioria dos pontos estão sobre a reta teórica sem a presença de arcos, indicando a satisfação do pressuposto de normalidade no q-qplot. Destaca-se, que embora existam alguns pontos de outliers, considerando o total de 2508 observações é esperada a presença de certa variabilidade nos resíduos.




Figura 5. Análise de resíduos via histograma (acima) e q-qplot (abaixo) para um dos modelos ajustados para o GNDVI.

Das considerações dos resíduos da Figura 5, concluímos que o modelo foi apropriado em descrever os dados com AIC de 40,81,  $R^2 = 0,98$ , e RMSE = 0,24. O modelo ajustado para esta área foi:

$$\text{Produtividade} = -0,01 + 5,91 \times \text{GNDVI}_{\text{DAS95}} \quad (3)$$

Como o modelo de regressão fornece uma medida global do talhão, foram gerados os mapas do GNDVI original de produtividade, dos valores ajustados e dos resíduos, a fim de acompanhar a similaridade de forma pontual. Conforme observa-se na Figura 6, o modelo captura as principais tendências em produtividade do talhão, apresentando maiores diferenças quando há valores muito discrepantes de sua vizinhança. Observando na escala original dos dados a maior diferença absoluta foi de 1,23 t/ha.

Como o modelo de regressão fornece uma medida global do talhão, foram gerados os mapas do GNDVI original de produtividade, dos valores ajustados e dos resíduos, a fim de acompanhar a similaridade de forma

pontual. Conforme observa-se na Figura 6, o modelo captura as principais tendências em produtividade do talhão, apresentando maiores diferenças quando há valores muito discrepantes de sua vizinhança. Observando na escala original dos dados a maior diferença absoluta foi de 1,23 t/ha.




Figura 6. Mapas de produtividade, produtividade estimada pelo GNDVI e resíduos para uma das áreas estudadas.

O aumento do uso de monitores de rendimento em colheitadeiras associados à disponibilidade de dados de imagens de sensoriamento remoto permite que as relações entre a produtividade e dados de imagens espectrais sejam avaliados de forma mais robusta e completa do que o uso de um número limitado de amostras para a estimativa de produtividade (YANG et al., 2013). Além disso, a disponibilidade cada dia maior de imagens com maior resolução espacial, temporal e espectral possibilita análises em escalas de talhão e sub-talhão. Essa capacidade de mapear a produtividade em nível de campo em uma região ao longo do tempo pode fornecer informações objetivas aos agricultores para melhorar as práticas de manejos agrônômicos e identificar lacunas de produtividade e, ainda, para melhorar os modelos de risco das companhias de seguros (JIN et al., 2017, SKAKUN et al., 2021).

BASSO et al. (2018) destacam que a simplicidade de um modelo de regressão estatística é também a força motriz para sua aplicabilidade, mas reforçam a sua limitação em extrapolar resultados para outras áreas fora dos limites dos dados observados. Entretanto, é importante ressaltar que os diversos estudos conduzidos em diferentes culturas e em diversas regiões do planeta têm apontado que os índices de vegetação explicam boa parte da produtividade dos talhões, de forma que, esses dados podem ser utilizados com certa segurança quando outras fontes de informação não estiverem disponíveis.

**CONCLUSÃO:** Nossos resultados destacam o potencial do uso de imagens do satélite Sentinel-2 para gerar estimativas de produtividade em escala de campo para a área de estudo. Observou-se que os índices de vegetação aqui analisados foram capazes de prever satisfatoriamente a produtividade. Esses resultados indicam que as imagens adquiridas durante a estação de crescimento podem ser utilizadas para mapear a variabilidade da produtividade dentro dos talhões para cada pixel da imagem e, desta forma, se apresentam como uma ferramenta muito útil para determinar os padrões de rendimento antes da colheita para a agricultura de precisão, auxiliando os manejos agrônômicos durante a safra.

Embora a produtividade possa ser analisada com modelos multivariados após o término de uma safra, como realizado nesse estudo, destaca-se que tais modelos não auxiliam na gestão agrícola, na estimativa de produtividade, lógica de mercado, entre outros, pois, ao término do ciclo já se dispõe do verdadeiro valor da produtividade e não há mais nada que possa ser feito para alterá-lo. Por outro lado, é valoroso ao setor o conhecimento do valor esperado antes do término do ciclo de cultura, quando ações efetivas ainda podem ser tomadas, além de permitir aos envolvidos maior controle e planejamento de suas atividades. Neste sentido, reforça-se a importância dos modelos univariados que foram investigados, pois, ao utilizarem uma única data permitiram estimar a produção a partir dos IVs disponíveis, o que fornece estimativas para ciclos ainda em andamento.

Como realizou-se o ajuste de um modelo para cada data, em algumas áreas, pode-se observar valores elevados de  $R^2$  em mais de um momento. Contudo, embora no início do ciclo os IVs possam indicar estimativas de produtividade elevadas, esta informação é vulnerável aos fatores que impactam sobre a agricultura. Assim, a identificação dos estádios fenológicos R4, R5 e R6 não somente indicam o valor esperado da produtividade

como também o faz em um momento em que as estimativas são menos suscetíveis as mudanças no ciclo e, portanto, mais confiáveis.

Apesar de modelos mais completos que utilizam dados agrometeorológicos associados a dados espectrais serem mais robustos, especialmente devido ao aumento da variabilidade climática e eventos extremos mais frequentes, estes são de difícil adequação, especialmente de forma automatizada, exigem conhecimento técnico especializado e não estão sempre disponíveis todas as informações necessárias para sua condução. Assim, a escolha de modelos como o proposto pode ser mais vantajosa devido à sua simplicidade, permitindo ilustrar os padrões existentes entre IVs e produtividade nas áreas sob análise. Porém, a extrapolação destes resultados exige análises mais sofisticadas e abrangentes.

Como trabalho futuro pretende-se ampliar as análises considerando um maior número de áreas, outras covariáveis, bem como, compreender padrões pontuais na imagem, suprimindo eventuais limitações deste estudo, ainda que os modelos tenham apresentado boa adequação.

## REFERÊNCIAS

AKAIKE, Hirotugu. A new look at the statistical model identification. **IEEE transactions on automatic control**, v. 19, n. 6, p. 716-723, 1974.

BECKER, Fernando Gertum; RAMOS, Ricardo Aranha; DE AZEVEDO MOURA, Luciano. **Biodiversidade: regiões da Lagoa do Casamento e dos Butiazais de Tapes, planície costeira do Rio Grande do Sul**. Brasília: Ministério do Meio Ambiente, 2007.

CHAMNAN, Kingkan. **Yield monitoring with Sentinel-2: A first assessment for The Netherlands**. 2021. Dissertação de Mestrado. University of Twente.

DANIEL, Wayne W.; CROSS, Chad L. **Biostatistics: a foundation for analysis in the health sciences**. Wiley, 2018.

EVANS, Fiona H.; SHEN, Jianxiu. Long-term hindcasts of wheat yield in fields using remotely sensed phenology, climate data and machine learning. **Remote Sensing**, v. 13, n. 13, p. 2435, 2021.

FOLEY, Jonathan A. et al. Solutions for a cultivated planet. **Nature**, v. 478, n. 7369, p. 337-342, 2011.

GARCÍA-MARTÍNEZ, Héctor et al. 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. 277, 2020.

GIANELLE, Damiano et al. Ecosystem carbon fluxes and canopy spectral reflectance of a mountain meadow. **International Journal of Remote Sensing**, v. 30, n. 2, p. 435-449, 2009.

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.

GITELSON, Anatoly; MERZLYAK, Mark N. Quantitative estimation of chlorophyll-a using reflectance spectra: Experiments with autumn chestnut and maple leaves. **Journal of Photochemistry and Photobiology B: Biology**, v. 22, n. 3, p. 247-252, 1994.

HUETE, Alfredo R.; JACKSON, Ray D.; POST, D. F. Spectral response of a plant canopy with different soil backgrounds. **Remote sensing of environment**, v. 17, n. 1, p. 37-53, 1985.

LAMBERT, Marie-Julie et al. Estimating smallholder crops production at village level from Sentinel-2 time series in Mali's cotton belt. **Remote Sensing of Environment**, v. 216, p. 647-657, 2018.

- MA, B. L. et al. Early prediction of soybean yield from canopy reflectance measurements. **Agronomy Journal**, v. 93, n. 6, p. 1227-1234, 2001.
- NAZIR, Abid et al. Estimation and Forecasting of Rice Yield Using Phenology-Based Algorithm and Linear Regression Model on Sentinel-II Satellite Data. **Agriculture**, v. 11, n. 10, p. 1026, 2021.
- R Core Team (2022). **R**: A language and environment for statistical computing. R Foundation for
- RENCHER, Alvin C.; SCHAALJE, G. Bruce. **Linear models in statistics**. John Wiley & Sons, 2008.
- ROSEGRANT, Mark W. et al. **Food security in a world of natural resource scarcity: The role of agricultural technologies**. Intl Food Policy Res Inst, 2014.
- ROUSE JR, John W. et al. **Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation**. 1973.
- SAMPAIO, M. I. R.; KUNZ, A.; HILLEBRAND, F. L.; ZAMBERLAN, J. F.; IDALINO, F. D. Análise dos índices de vegetação NDVI e NDRE em imagens obtidas por meio de sensor embarcado em um RPAS para as culturas da soja (*Glycine max*) e milho (*Zea mays*) irrigados. **R. bras. Geom.**, Curitiba, v. 9, n. 4, p. 350-362, 2021.
- SCHWALBERT, Raí A. et al. Satellite-based soybean yield forecast: Integrating machine learning and weather data for improving crop yield prediction in southern Brazil. **Agricultural and Forest Meteorology**, v. 284, p. 107886, 2020.
- SKAKUN, Sergii et al. Assessing within-field corn and soybean yield variability from WorldView-3, Planet, Sentinel-2, and Landsat 8 satellite imagery. **Remote Sensing**, v. 13, n. 5, p. 872, 2021.
- Statistical Computing, Vienna, Austria. URL:<https://www.R-project.org/>. v. 4.1.1.
- VAN DIJK, Michiel et al. A meta-analysis of projected global food demand and population at risk of hunger for the period 2010–2050. **Nature Food**, v. 2, n. 7, p. 494-501, 2021.
- VENABLES, William N.; RIPLEY, Brian D. **Modern applied statistics with S-PLUS**. Springer Science & Business Media, 2013.
- VOGEL, Jonathan T. et al. Soybean Yield Formation Physiology—A Foundation for Precision Breeding Based Improvement. **Frontiers in plant science**, v. 12, 2021.
- XUE, J.; SU, B. Significant remote sensing vegetation indices: a review of developments and applications. **Journal Sensors** 2017: 1–17. 2017.
- YANG, Chenghai et al. Using high-resolution airborne and satellite imagery to assess crop growth and yield variability for precision agriculture. **Proceedings of the IEEE**, v. 101, n. 3, p. 582-592, 2012.
- ZHAO, Yan et al. Predicting wheat yield at the field scale by combining high-resolution Sentinel-2 satellite imagery and crop modelling. **Remote Sensing**, v. 12, n. 6, p. 1024, 2020.

# CONFIGURAÇÕES AMOSTRAIS DIRIGIDAS POR UNIDADES DE GESTÃO DIFERENCIADA PARA FERTILIDADE DO SOLO

Mateus Borges Naciben<sup>1</sup>; Henrique Oldoni<sup>2</sup>; Thiago Luís Brasco<sup>3</sup>; Maiara Pusch<sup>4</sup>; Lucas Rios do Amaral<sup>5</sup>

<sup>1</sup>Graduando em engenharia agrícola, Graduando - Faculdade de Engenharia Agrícola, FEAGRI, UNICAMP, Campinas - SP. mateus.naciben@hotmail.com / (19) 9 9121-7931; <sup>2</sup>Eng<sup>o</sup> Agrícola, Dr., Pós-doutorando - Núcleo Interdisciplinar de Planejamento Energético - NIPE, R. Cora Coralina, 330 - Cidade Universitária, Campinas - SP; <sup>3</sup>Eng<sup>o</sup> Agrícola, Mestrando no programa de Pós-Graduação em Engenharia Agrícola - Faculdade de Engenharia Agrícola, FEAGRI, UNICAMP, Campinas - SP; <sup>4</sup>Eng<sup>o</sup> Agrícola, Dr., Doutora no programa de Pós-Graduação em Engenharia Agrícola - Faculdade de Engenharia Agrícola, FEAGRI, UNICAMP, Campinas - SP; <sup>5</sup>Eng<sup>o</sup> Agrônomo, Dr., Professor - Faculdade de Engenharia Agrícola, FEAGRI, UNICAMP, Campinas - SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Uma das maneiras para orientação da amostragem de solo em agricultura de precisão (AP) é com base em unidades de gestão diferenciada (UGDs). Contudo, pouco se sabe sobre a interferência da escolha dos locais de subamostragens na qualidade da amostra composta de cada UGD. Neste trabalho, o objetivo foi avaliar se diferentes configurações amostrais no interior das UGDs interferem na qualidade amostral dos atributos de fertilidade do solo. Para isso foram delimitadas UGDs em uma área agrícola de 106 ha com base em dados de condutividade elétrica aparente do solo e elevação do terreno. A partir da configuração amostral original (uma amostra por hectare), outras três configurações amostrais foram propostas com redução para 40% do número de amostras total em cada UGD: aleatória, zigue-zague latitudinal e zigue-zague longitudinal, de modo a simular tipos de amostragem de densidade reduzida no interior de UGDs. Os dados de potássio (K), capacidade de troca catiônica (CTC) e saturação por bases (V%) das amostras coletadas em cada configuração amostral foram comparados de modo a avaliar diferenças entre amostragens e UGDs. Houve diferença significativa entre os dados de K e CTC entre as UGDs. Não houve diferença entre as configurações amostrais para os três atributos avaliados. Com isso, as diferentes configurações amostrais não afetaram a qualidade de amostragem dos atributos de fertilidade do solo no interior de cada UGD.

**PALAVRAS-CHAVE:** variabilidade espacial; amostragem de solo; zona de manejo

## SOIL SAMPLING SCHEMES DIRECTED BY MANagements ZONES FOR SOIL FERTILITY

**ABSTRACT:** One of the ways to guide soil sampling in precision agriculture (PA) is based on management zones (MZ). However, little is known about the interference of the choice of subsample arrangement on the quality of the composed sample for each MZ. In this sense, the objective was to evaluate whether different sampling configurations within the MZ interfere with the sampling quality of soil fertility attributes. For this, UGDs were delimited in an agricultural area of 106 ha based on apparent soil electrical conductivity data and terrain elevation. From the original sample configuration (one sample per hectare), three other sample configurations were proposed with a reduction to 40% of the total number of samples in each MZ: random, latitudinal zigzag and longitudinal zigzag, in order to simulate types density sampling within MZs. Potassium (K), cation exchange capacity (CTC) and base saturation (V%) data of samples collected in each sampling configuration were compared in order to assess differences between samples and MZs. There was a significant difference between the K and CTC data in each MZ. There was no difference between the sample configurations for the three attributes evaluated. Therefore, the different sampling configurations did not affect the sampling quality of soil fertility attributes within each MZ.

**KEYWORDS:** spatial variability; soil sampling; sample configurations

**INTRODUÇÃO:** A amostragem de solo representa um dos processos essenciais para caracterização da variabilidade dos solos. Os esquemas amostrais podem ser definidos por pontos, célula, amostragem dirigida

ou com base em unidades de gestão diferenciada (UGDs), que consistem na divisão da área agrícola em sub-regiões de acordo com combinações de fatores limitantes de produtividade (ALMEIDA et al., 2014). Ou seja, as áreas devem apresentar o mínimo de variabilidade dentro das sub-regiões. As UGDs podem ser manejadas com os mesmos sistemas empregados na agricultura convencional, de modo a serem aplicadas doses uniformes de insumos para cada sub-região, uma vez que não restará variabilidade significativa dentro da mesma (IICA, 2014). Por isso, é preciso amplo conhecimento da variabilidade dos fatores de produção presentes na área de estudo.

Um dos impasses enfrentados pela agricultura de precisão (AP) é a necessidade de uma densa base de dados, para se gerar um mapa que represente a realidade da área em análise (RODRIGUES JUNIOR et al., 2011). Alguns fatores válidos na delimitação das UGDs são a condutividade elétrica aparente do solo (ECa) e a matéria orgânica (Alves et al., 2013). Outras variáveis de importância para a definição das UGDs são as características de terreno, como a elevação e declividade, que condiciona as propriedades físico-químicas do solo, sendo determinante na heterogeneidade das regiões manejadas (KUIAWSKI et al., 2017).

Com a definição de UGDs, subamostras são coletadas no interior de cada delimitação para a composição de uma única amostra por UGD. Desse modo, ocorre uma redução considerável na quantidade de pontos amostrados em comparação com a amostragem em malhas, o que reflete na redução de custos de amostragem (CHERUBIN et al., 2016). Contudo, pouco se sabe sobre a interferência da escolha dos locais de subamostragens na qualidade da amostra composta de cada UGD e, conseqüentemente, dos valores dos atributos de fertilidade. Portanto, o objetivo deste trabalho foi avaliar se diferentes configurações amostrais no interior das UGDs interferem na qualidade amostral dos atributos de fertilidade do solo.

**MATERIAIS E MÉTODOS:** A área de estudo está localizada na Fazenda São José, município de Cosmópolis - SP. Possui 106 ha onde, a partir de 2019, iniciou-se o cultivo em sucessão entre soja e sorgo, com a cultura da soja cultivada no período da safra e o sorgo na entressafra (safrinha).

Em 2020, dados de solo foram coletados na área de estudo em uma malha amostral de 109 pontos georreferenciados (densidade amostral de uma amostra por hectare) na camada de 0 – 0,2 m de profundidade. Os pontos da malha amostral foram alocados seguindo distribuição otimizada com a função objetivo focando na manutenção da distância mínima entre pontos amostrados e locais de predição (WALVOORT, et al., 2010). As amostras foram coletadas com quadriciclo instrumentado com amostrador tipo broca, coletando quatro subamostras no interior de um raio de 4 m do ponto georreferenciado, para representar cada amostra composta. Dados de potássio (K), capacidade de troca catiônica (CTC) e valores de saturação por bases (V%) foram determinados para cada amostra composta.

Além disso, foram coletados dados de condutividade elétrica aparente do solo (CEa) na área de estudo, utilizando o sensor proximal EM38-MK2® (Geonics, Mississauga, Ontário, Canadá) na camada de 0 a 0,38 m de profundidade, com passadas a cada 30 m; e dados de elevação do terreno, a partir de GNSS embarcado em colhedora, com passadas a cada 7,6 m. Tanto os dados de CEa e elevação foram submetidos ao procedimento de filtragem de dados para remoção de outliers e inliers, seguindo o método apresentado por Maldaner et al. (2018, 2022). Após isso, os dados de CEa e elevação foram submetidos a análise geoestatística e interpolação por krigagem para a construção de mapas com resolução espacial de 10 m.

Para a construção das UGDs, inicialmente os dados interpolados de CEa e elevação foram padronizados pelo método do z-score, em seguida submetidos à análise espacial multivariada baseada no índice de Moran e componentes principais (MULTISPATI-PCA) (DRAY et al., 2008). A partir disso, selecionaram-se as componentes principais espaciais (sPC) que juntas somaram mais de 70% da variância total como variáveis de entrada para a análise de agrupamento fuzzy k-means (BEZDEK et al., 1984), seguindo recomendações de Córdoba et al. (2016). Testaram-se entre dois e cinco grupos, dos quais foi escolhido o melhor número baseado em três funções: índice de desempenho fuzziness (FPI), entropia de partição modificada (MPE) e largura de silhueta (SW), em que quanto menor forem os valores de FPI e MPE e maior o valor de SW, maior será a qualidade dos agrupamentos gerados. Deste modo, o mapa de UGDs foi gerado a partir dos resultados da análise de agrupamento para o melhor número de grupos, ou seja, melhor número de UGDs.



A partir da configuração amostral original (grade amostral de 109 pontos), adotada como amostragem de referência, outras três configurações foram construídas em cada UGD, todas correspondentes a 40% de redução da quantidade de pontos original. Deste modo simularam-se três tipos de amostragem de densidade reduzida no interior de cada UGD. A configuração denominada aleatória foi construída a partir da seleção de pontos aleatoriamente em cada UGD. Para as demais configurações foram propostos dois diferentes caminhamentos em zigue-zague (ZZ) para seleção dos pontos de amostragem. Um dos caminhamentos em ZZ, denominado de ZZ longitudinal, seguiu a direção Leste-Oeste, já o caminhamento denominado ZZ latitudinal seguiu a direção Norte-Sul. Os caminhamentos em zigue-zagues foram estabelecidos de acordo com a disposição que melhor representou a área de cada UGD e foram adotados os pontos amostrais próximos de cada caminhamento.

Os dados de K, CTC e V% foram submetidos aos testes de normalidade de Shapiro-Wilk e homogeneidade da variância de Bartlett. Após isso, os mesmos dados foram submetidos ao teste não paramétrico Kruskal-Wallis para avaliar a existência de diferença entre as quatro configurações amostrais de cada UGD e entre UGDs; e ao teste post-hoc de Dunn para as comparações múltiplas, com ajuste de p-valor pelo método de Bonferroni. Adotou-se em todos os testes um nível de significância de 5%.

**RESULTADOS E DISCUSSÃO:** O número de duas UGDs foi adotado como a melhor escolha, visto que duas das três funções adotadas indicou a maior qualidade de agrupamentos quando dois grupos eram adotados (menor FPI e maior SW; FIGURA 1). Deste modo, duas UGDs foram delimitadas na área e, a partir disso, as diferentes configurações de amostragem foram estabelecidas (FIGURA 2).




FIGURA 1. Índice de desempenho fuzziness (FPI), entropia de partição modificada (MPE) e largura de silhueta (SW) para cada número de unidades de gestão diferenciada (UGDs). **The Fuzzy Performance Index (FPI), Modified Partition Entropy (MPE) and Silhouette Width (SW) for each number of management zones (MZ).**

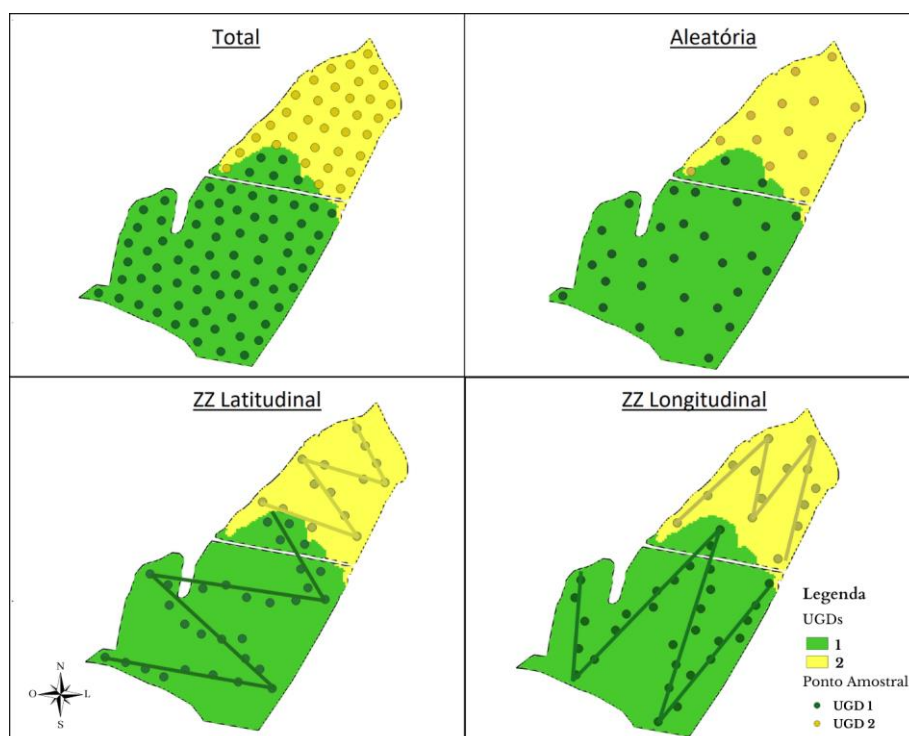


FIGURA 2. Unidades de gestão diferenciada (UGDs) com representação dos pontos de amostragem nas configurações total, aleatória, zigue-zague latitudinal (ZZ Latitudinal) e zigue-zague longitudinal (ZZ Longitudinal). **Management zones (MZ) with representation of sampling points in total, random, latitudinal zigzag (Latitudinal ZZ) and longitudinal zigzag (Longitudinal ZZ).**

Os dados de CTC, V% e K apresentaram homogeneidade de variância ( $p$ -valor  $> 0,05$ ) para todas as configurações amostrais testadas em cada UGD, indicando que não houve mudança significativa da variância dos dados nos diferentes tipos de amostragem. Estes mesmos conjuntos de dados apresentaram não normalidade ( $p$ -valor  $< 0,05$ ), resultando na necessidade da utilização de teste não paramétrico no procedimento de comparação entre os dados das diferentes configurações amostrais e UGDs, como apresentado na Figura 3.

Os resultados do teste de comparação múltipla de Dunn obtidos para os dados de K mostram que esta variável não apresentou diferença ( $p$ -valor-ajustado  $> 0,05$ ) entre as configurações amostrais dentro da mesma UGD (FIGURA 3). Por outro lado, todas apresentaram diferença significativa ( $p$ -valor-ajustado  $\leq 0,05$ ) entre UGDs dentro de uma mesma configuração amostral, com exceção para a amostragem em ZZ longitudinal, a qual resultou em semelhança entre UGDs quanto aos níveis de K do solo. Embora isso tenha ocorrido, a configuração amostral ZZ longitudinal não diferiu da configuração total (referência) em cada UGD separadamente.

Da mesma forma que os dados de K, a CTC não diferiu ( $p$ -valor-ajustado  $> 0,05$ ) entre as configurações amostrais dentro da mesma UGD (FIGURA 3). Além disso, houve diferença significativa ( $p$ -valor-ajustado  $\leq 0,05$ ) entre as UGDs, independentemente da configuração amostral. Tanto os níveis de K como de CTC, foram maiores na UGD 2.

No caso dos níveis de V% do solo, não houve diferença significativa ( $p$ -valor-ajustado  $> 0,05$ ) tanto entre as UGDs, quanto entre as diferentes configurações amostrais. Isso mostra que mesmo que as UGDs não permitiram a separação desse atributo em níveis distintos, as configurações amostrais seguem não interferindo no valor final do atributo. Além disso, indica que o delineamento de UGDs não garante a separação de diferentes níveis de fertilidade para todos os atributos de fertilidade. Neste caso, esses atributos, como é o caso do V%, devem ser amostrados independentemente das UGDs.

Portanto, esse estudo mostra que independentemente das configurações amostrais no interior das UGDs, os valores médios das propriedades de fertilidade do solo permanecem constantes, mostrando que qualquer desses métodos de amostragem podem ser seguidos sem prejuízo ao valor final do atributo. Esses resultados sustentam

o pressuposto de que as UGDs devem delimitar sub-regiões com características de solo internamente similares (CÓRDOBA et al., 2016; MORAL et al., 2010). Contudo, é importante destacar que neste estudo foram coletadas 30 subamostras para a UGD 1 e 14 para a UGD 2 (40% da amostragem total), o que são números elevados. Acreditamos que quanto maior a redução no número de subamostras, mais o valor médio pode sofrer alterações. Isso mostra que a questão do número de subamostras ainda não é questão resolvida nos mapeamentos em agricultura de precisão.

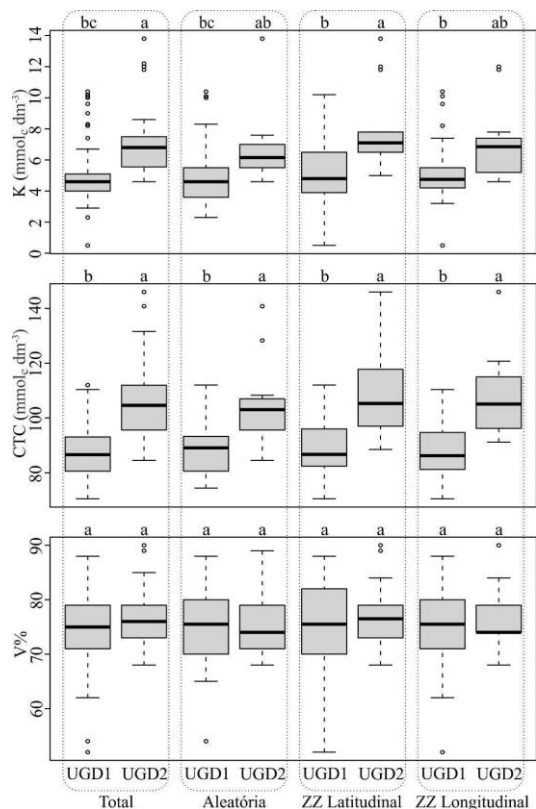


FIGURA 3. Boxplots dos valores de potássio (K), capacidade de troca catiônica (CTC) e saturação por bases (V%) das subamostras nos diferentes tipos de amostragem em cada unidade de gestão diferenciada (UGD). Diferentes letras para um mesmo atributo representam diferença significativa pelo teste post-hoc de Dunn ( $p$ -valor-ajustado $\leq 0,05$ ) entre configurações amostrais e entre UGDs. **Boxplots of potassium values (K), cationic exchange capacity (CTC) and base saturation (V%) on different types of soil sampling in each management zone (MZ). Different letters for the same attribute represent a significant difference by Dunn's post-hoc test (adjusted  $p$ -value $\leq 0.05$ ) between sample configurations and between MZs.**

**CONCLUSÃO:** A forma de coleta de subamostras dentro das UGDs parece não impactar na representação média dos valores de fertilidade do solo. A questão do número de subamostras precisa ser investigada em estudos futuros.

#### AGRADECIMENTOS:

Aos integrantes do Grupo Interdisciplinar de Agricultura de Precisão (GITAP) da Faculdade de Engenharia Agrícola da Unicamp; ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq); à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), processos nº 2017/50205-9 e 2020/02223-0; à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001 e à Fazenda São José pelo apoio e disponibilização de dados para a realização deste trabalho.

#### REFERÊNCIAS

ALMEIDA, A. C. S. et al. **Métodos para a definição de unidades de gestão diferenciada**. Congresso Brasileiro de Agricultura de Precisão. **Anais...**São Pedro, SP: set. 2014

ALVES, S. M. F. et al. Definição de zonas de manejo a partir de mapas de condutividade elétrica e matéria orgânica. **Bioscience Journal**, Uberlândia, v.29, n. 1, p. 104-114, 2013.

BEZDEK, J.C., EHRLICH, R., FULL, W. FCM: the fuzzy c-means clustering algorithm. **Computers & Geosciences**, v. 10, p. 191–203, 1984

CHERUBIN, M. R. et al. Amostragem de solo na agricultura de precisão. In: SANTI, A. L. et al. **Agricultura de Precisão no Rio Grande do Sul**. 1ª ed. Santa Maria: CESPOL, 2016.

CÓRDOBA, M. A. et al. Protocol for multivariate homogeneous zone delineation in precision agriculture. **Biosystems Engineering**, v.43, p. 95-107, fev. 2016

DRAY, S.; SAÏD, S.; DÉBIAS, F. Spatial ordination of vegetation data using a generalization of Wartenberg's multivariate spatial correlation. **Journal of Vegetation Science**, v. 19, n. 1, p. 45-56, 2008.

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.

INSTITUTO INTERAMERICANO DE COOPERACIÓN PARA LA AGRICULTURA, **Manual de agricultura de precisión**. Montevideo, 176p., 2014. ISBN: 978-92-9248-545-0

KUIAWSKI, A. C. M. B. et al. Índices de vegetação na delimitação de zonas de manejo para a soja. **Pesquisa Agropecuária Tropical**, Goiânia, v. 47, n. 2, p. 168–177, 2017. Disponível em: <https://www.revistas.ufg.br/pat/article/view/43904>. Acesso em: 24 abr. 2022.

LI, Y. et al. Determination of potential management zones from soil electrical conductivity, yield and crop data. **Journal of Zhejiang University. Science. B**, Hangzhou, v. 9, n. 1, p. 68-76, 2008

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.1-7, 2022.

MALDANER, L. F.; MOLIN, P.; SENTELHAS, P. C. Data processing within rows for sugarcane yield mapping. **Scientia Agricola** v.77, n.5. 2018

MORAL, F. J.; TERRÓN, J. M.; SILVA, J. R. M. Delineation of management zones using mobile measurements of soil apparent electrical conductivity and multivariate geostatistical techniques. **Soil and Tillage Research**, v.106, n.2, p.335-343, 2010.

RODRIGUES JUNIOR, F.A. et al. Geração de zonas de manejo para cafeicultura empregando-se sensor SPAD e análise foliar. Campina Grande. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.15, n.8, p.778-787, 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.

WALVOORT, D.J.J.; BRUS, D.J.; GRUIJTER, J.J.de. An R package for spatial coverage sampling and random sampling from compact geographical strata by k-means. **Computers & Geosciences**, v.36, n.10, p. 1261-1267, 2010.

# ÍNDICE DE REFLECTÂNCIA DE SENESCÊNCIA DE PLANTAS EM VIDEIRAS

Lúcio de Paula Amaral<sup>1</sup>; Regiane Aparecida Ferreira<sup>2</sup>; Luiz Felipe Diaz de Carvalho<sup>3</sup>; Aline de Oliveira Fogaça<sup>4</sup>; Luciano Gebler<sup>5</sup>

<sup>1</sup>Engenheiro Florestal, Professor - DER-CCR/UFSM, UFSM, Santa Maria-RS, Brasil. lucio.amaral@ufsm.br / (55) 9 9163-3398; <sup>2</sup>Engenheira Florestal, Pós-graduanda (Mestrado Profissional em Agricultura de Precisão) - PPGAP-Colégio Politécnico/UFSM, UFSM, Santa Maria-RS, Brasil; <sup>3</sup>Engenheiro Agrônomo, Professor - Colégio Politécnico/UFSM, UFSM, Santa Maria-RS, Brasil; <sup>4</sup>Engenheira Agrônoma, Professor - Vinícola Velho Amâncio, Itaara-RS, Brasil; <sup>5</sup>Engenheiro Agrônomo, Pesquisador - EMBRAPA ? Uva e Vinho, Estação Experimental de Fruticultura de Clima Temperado, Vacaria-RS, Brasil

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** A Viticultura de Precisão no Brasil ainda é insipiente, há necessidade de desenvolver tecnologias e/ou adaptações de tecnologias para coleta de dados e geração de informações espaciais nos pomares, bem como de equipamentos para manejo e intervenções nas áreas de produção de videiras. Este trabalho descreve o mapeamento de variabilidade espacial em videiras na vinícola Velho Amâncio, com implantação de um projeto piloto de vitivinicultura de precisão. Em uma gleba de 1,3 ha de cultivo das castas *Cabernet Sauvignon* e *Syrah*, localizadas em Itaara-RS, foi realizado mapeamento com aeronave remotamente pilotada (RPA) *Phantom 4 DJI* e sensor multiespectral *Red Edge-Mx Micasense*, para geração do índice de reflectância de senescência de plantas (PSRI). O processamento das imagens ocorreu no *software Metashape Agisoft*, com correção radiométrica das imagens (painel de calibração + sensor de luminosidade). O mosaico do PSRI apresentou resolução espacial melhor do que 10 cm e foi importado para o sistema de informação geográfica *Arc Map*, onde foi reclassificado. Foi possível distinguir os elementos do pomar plantas de videira, falhas, entre linha coberta com plantas espontâneas, solo exposto e sombra. Foi gerado um mapa contendo as classes videira, entre linha e solo exposto. Conclui-se que o PSRI detectou elementos importantes do pomar, detectou variabilidade espacial na vegetação e pode ser indicado para trabalhos de viticultura de precisão.

**PALAVRAS-CHAVE:** Vitivinicultura de Precisão; Aeronave Remotamente Pilotada; Sensoriamento Remoto

## PLANT SENESCENCE REFLECTANCE INDEX IN VINEYARDS

**ABSTRACT:** Precision Viticulture in Brazil is still incipient, there is a need to develop technologies and/or adaptations of technologies for data collection and generation of spatial information in the orchards, as well as equipment for management and interventions in the areas of vine production. This work describes the mapping of spatial variability in vines at the Velho Amâncio winery, with the implementation of a pilot project of precision viticulture. In a plot of 1.3 ha cultivated with Cabernet Sauvignon and Syrah, located in Itaara-RS, mapping was carried out with a remotely piloted aircraft (RPA) Phantom 4 DJI and a Red Edge-Mx Micasense multispectral sensor to generate the Plant Senescence Reflectance Index (PSRI). The images were processed using the Metashape Agisoft software, with radiometric correction of the images (calibration panel + light sensor). The PSRI mosaic showed a spatial resolution better than 10 cm and was imported into the Arc Map geographic information system, where it was reclassified. It was possible to distinguish the elements of the orchard, vine plants, faults, between a line covered with spontaneous plants, exposed soil and shade. A map was generated containing the vine classes, between row and exposed soil. It is concluded that the PSRI detected important elements of the orchard, detected spatial variability in the vegetation and can be indicated for precision viticulture work.

**KEYWORDS:** Precision Viticulture; UAV; Remote Sensing

**INTRODUÇÃO:** A Vinícola Velho Amâncio é uma pequena casa vinícola, com vinhedos próprios, produções limitadas, exclusivas e administração familiar. Tem sua origem a mais de 100 anos, nos quais por duas gerações manteve uma destilaria para produção de cachaça, iniciando a produção de vinhos em 1986, explorando o

*terroir* do Vale Central Gaúcho (VELHO AMÂNCIO, 2022). Assim como já ocorre na Viticultura, a Vinícola Velho Amâncio também começou a experimentar tecnologias de Agricultura de Precisão para melhor conhecer a variabilidade espacial de atributos de solo e plantas em seus pomares, iniciando um projeto piloto de vitivinicultura de precisão, com uso de aeronaves remotamente pilotadas (RPA) e sensor multiespectral para geração de índices de vegetação (IV).

As RPA, também conhecidas por drones e vants, juntamente com seus sensores, são atualmente umas das tecnologias de maior destaque na Agricultura de Precisão (CASTRO JORGE e INAMASU, 2014; MOLIN et al., 2015). Dentre as aplicações das imagens geradas por sensores embarcados em RPA o uso dos IV tem grande destaque para geração de informações que auxiliem na tomada de decisão sobre manejo e tratamentos culturais, quando integrados a um sistema de multicamadas de informações.

O índice de reflectância de senescência de plantas (PSRI) utiliza as bandas espectrais do verde, vermelho e borda do vermelho, tem sensibilidade semelhante a do NDVI, responde aos teores de carotenóides (alfacaroteno e beta-caroteno, por exemplo). Seus valores variam de -1 a 1, aumentam durante a senescência de folhas, ao aumentar o teor de carotenóides em relação às clorofilas, e também na maturação de frutos. O nível de severidade de doenças e outros estresses, a exemplo do déficit hídrico, também podem desequilibrar a relação carotenóides/clorofilas, desta forma o PSRI pode ser interessante para a viticultura. Suas aplicações incluem monitoramento da saúde da vegetação, detecção de estresse fisiológico de plantas, produção de culturas e análise de rendimento (MERZLYAK et al., 1999; REN, CHEN e AN, 2017).

O objetivo deste trabalho foi determinar o PSRI, demonstrar sua variabilidade em videiras na safra 2021/2022 e contribuir para trabalhos futuros que visam determinar zonas de produção diferenciadas em uma gleba/vinhedo na Vinícola Velho Amâncio, na região da Depressão Central do Rio Grande do Sul.

**MATERIAIS E MÉTODOS:** O projeto piloto está sendo realizado em uma gleba de  $\approx 1,3$  ha com cultivo de videiras (*Vitis vinifera* L.) das castas *Cabernet Sauvignon* e *Syrah* (Figura 1), conduzidas em espaldeiras, na Vinícola Velho Amâncio, em Itaara, Região Central do Rio Grande do Sul, Brasil.




FIGURA 1. Área de implantação do projeto piloto de vitivinicultura de precisão, com videiras Cabernet Sauvignon e Syrah na Vinícola Velho Amâncio, Itaara-RS, Brasil. Area of implantation of the pilot project of viticulture of precision, with vines Cabernet Sauvignon and Syrah field in the Vinícola Velho Amâncio, Itaara-RS, Brazil.

Foi realizado um voo com RPA multirrotor *Phantom 4 DJI* com sensor multiespectral *RedEdge-Mx Micasense*, em 10 de dezembro de 2021. O aplicativo para planejamento de missão utilizado foi o *Precision Flight*, com recobrimentos longitudinal e lateral de 75% para a RPA. O sensor multiespectral foi configurado para ser



acionado por *timer*, com intervalo de geração das imagens em 1,6 segundos, recobrimentos de 75%, previstos pelo fabricante (MICASENSE, 2015). Este sensor possui cinco bandas espectrais [*Blue* 475 ±20 nm (Azul), *Green* 560 ±20 nm (Verde), *Red* 668 ±10 nm (vermelho), *Near Infrared* ±40 nm (infravermelho próximo) e *Red Edge* 717 ±10 nm (borda do vermelho)]. Possui painel de calibração de reflectância, que funciona como uma superfície lambertiana, e sensor de luminosidade DSL para captura de variabilidade de radiação no momento da geração das imagens, ambos foram utilizados na calibração radiométrica das imagens durante o processamento (MICASENSE, 2015).

O processamento foi realizado no *software Metashape Agisoft*, com qualidade mediana, sendo gerados os mosaicos RGB e do índice de reflectância de senescência de plantas (PSRI), ambos com 10 cm de resolução espacial, georreferenciado em coordenadas geográficas e *Datum* WGS84. No sistema de informação geográfica *ArcMap*, foi realizada a delimitação do talhão, corte dos mosaicos para a área de interesse e classificação do mosaico do IV PSRI. O índice PSRI é dado por (MERZLYAK et al., 1999):

$$PSRI = \frac{(Red - Green)}{Red\ Edge} \quad (1)$$

em que : *Red* = banda do vermelho; *Green* = banda do verde; *Red Edge* = banda da borda do vermelho.

**RESULTADOS E DISCUSSÃO:** Os valores obtidos para o índice PSRI na gleba em análise variaram de -0,5984 a 0,2528 (Figura 2). A literatura indica que para a vegetação verde os valores geralmente se encontram no intervalo de -0,1 a 0,2 (MERZLYAK et al., 1999). Na amplitude de dados observada na gleba em análise, estão contidos valores referentes às videiras, sombra, cobertura da entre linha com plantas espontâneas (folhas estreita e folhas largas) e solo exposto. O índice PSRI foi sensível para destacar estes componentes diferentes (Figura 3).




FIGURA 2. Mosaico do índice de reflectância de senescência de plantas – PSRI obtidos na gleba de videiras Cabernet Sauvignon e Syrah na Vinícola Velho Amâncio, Itaara-RS, Brasil – dezembro de 2021. Mosaic of plant senescence reflectance index – PSRI obtained from Cabernet Sauvignon and Syrah vines field at Vinícola Velho Amâncio, Itaara-RS, Brazil – December 2021.

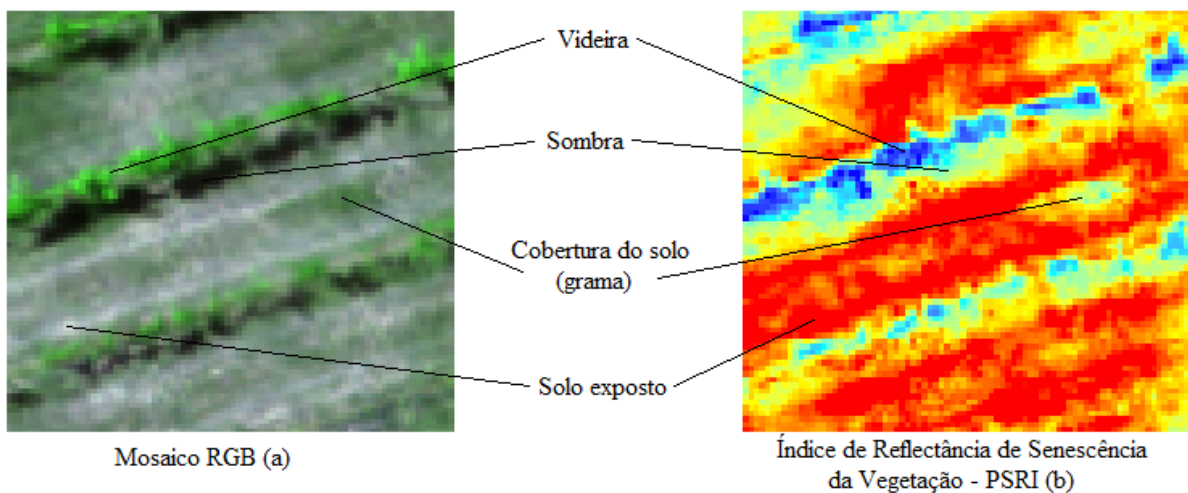


FIGURA 3. Distinção de videiras, sombra, plantas espontâneas de cobertura na entre linha e solo exposto no Mosaico RGB (a) e no índice de reflectância de senescência de plantas - PSRI (b) obtidos na gleba de videiras Cabernet Sauvignon e Syrah na Vinícola Velho Amâncio, Itaara-RS, Brasil – dezembro de 2021. Distinction of vines, shade, weeds between the row and exposed soil in the Mosaic RGB (a) and in the plant senescence reflectance index - PSRI (b) obtained in Cabernet Sauvignon and Syrah vines field at the Velho Amâncio Winery, Itaara-RS , Brazil – December 2021.

Na reclassificação do PSRI, ao usar inicialmente estas quatro classes (videira, sombra, entrelinha com cobertura e solo exposto), foi observado que a classe sombra tem seus valores dentro dos limites da classe entrelinha com cobertura. Em uma segunda reclassificação a classe sombra foi incorporada a da entrelinha com cobertura, sendo individualizadas as classes videira e solo exposto (Figura 4).




FIGURA 4. Classificação do índice de reflectância de senescência de plantas - PSRI obtidos em videiras Cabernet Sauvignon e Syrah na Vinícola Velho Amâncio, Itaara-RS, Brasil – dezembro de 2021. Classification of plant senescence reflectance index - PSRI obtained from Cabernet Sauvignon and Syrah vines at Vinícola Velho Amâncio, Itaara-RS, Brazil – December 2021.

Aparentemente as plantas com menores teores de carotenóides apresentaram valores de PSRI mais negativos, ou seja, com maiores teores de clorofila (MERZLYAK et al., 1999; REN, CHEN e AN, 2017). Quando as espécies estão sob estresse ou durante a senescência foliar, os teores de clorofila tendem a diminuir mais rapidamente em relação aos teores de carotenóides (SIMS e GAMON, 2002). No entanto, as plantas espontâneas da entrelinha do pomar também apresentaram estes padrões e foram classificadas como videiras, sendo necessário filtragem de dados para excluir pixels classificados nesta classe presentes na entrelinha.



As manchas de solo exposto obtidas delimitam possíveis áreas com déficit hídrico, em função da forte estiagem observada em dezembro de 2021. Estas manchas representam diferentes ambientes na gleba em estudo e podem ser utilizadas para delimitação futura de zonas no pomar, para orientar colheita diferenciada e avaliação de parâmetros de qualidade e produção (KING et al., 2014). Esta delimitação será realizada baseada na utilização de multicamadas de informações (atributos de solo e vegetação), dentre as quais o PSRI será considerado. A literatura relata que que atributos dos vinhedos, tais como resposta espectrais das folhas, condutividade elétrica do solo e rendimentos podem ser relacionados com a variabilidade espacial do vigor vegetativo por meio de índices de vegetação (BONILLA et al., 2015; OLDONI, 2019). Zonas homogêneas de vigor vegetativo podem auxiliar na definição de manejos específicos para cada ambiente (sítio específico, *terroir*) nos vinhedos.

O PSRI tem sido utilizado para apontar condições de estresse na vegetação, parâmetro de avaliação de condições favoráveis a incêndios florestais, diferentes níveis de severidade de infecção da bactéria *Erwinia psidii* em árvores de *E. urograndis* (MERZLYAK et al., 1999; PEDRALLI, 2017; TEIXEIRA, 2020). Já para esta pesquisa, o ideal é acompanhar a evolução temporal do PSRI no pomar de videiras, a exemplo do que é feito com o NDVI (JUNGES et al., 2017), a fim de explorar todo o seu potencial.

**CONCLUSÃO:** O índice PSRI mostrou-se sensível para distinguir videira de outros elementos no pomar, além de indicar onde as plantas podem estar sob estresse e apresentam menor vigor. Assim, o PSRI pode ser indicado para trabalhos de Agricultura de Precisão em Viticultura e outras pesquisas devem ser desenvolvidas para conhecer melhor relações entre o comportamento deste índice e os atributos dos vinhedos.

#### **AGRADECIMENTOS:**

À Vinícola Velho Amâncio, pela disponibilização de seu pomar, e ao Projeto Aquarius/UFSM, pela disponibilidade do sensor multiespectral utilizado neste trabalho e ao Professor Lúcio de Paula Amaral pela disponibilidade da aeronave remotamente pilotada.

#### **REFERÊNCIAS**

BONILLA, I.; MARTÍNEZ, T. F.; MARTÍNEZ-CASANOVAS, J. A. Vine vigor, yield and grape quality assessment by airboe remote sensing over three years: analysis of unexpected relationships in cv. Tempranillo. **Spanish Journal of Agricultural Research**, v. 13, n. 2, p.1-8, 2015. DOI: 10.5424/sjar/2015132-7809.

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.

KING, P. D. et al. Within-vineyard variability in vine vegetative growth, yield, and fruit and wine composition of Cabernet Sauvignon in Hawke's Bay, New Zealand. **Australian Journal of Grape and Wine Research**, v. 20, n. 2, p.234-246, 2014.

OLDONI, H. **Zonas homogêneas de atributos de planta e do solo em vinhedo irrigado**. 2019. Tese (Doutorado em Agronomia – Irrigação e drenagem), FCA/UNESP, Botucatu, 2010.

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**, v. 81, n. 2-3, p. 337-354, 2002.

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.

CASTRO JORGE, L. A.; INAMASU, R. Y. Uso de veículos aéreos não tripulados (VANT) em agricultura de precisão. In: BERNARDI, A. C. C.; NAIME, J. M.; RESENDE, A. V.; BASSOI, L. H.; INAMASU, R.

Y. **Agricultura de Precisão**: resultado de um novo olhar. Brasília: EMBRAPA, 2014. 596 p. Disponível em:<<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/114264/1/CAP-8.pdf>>. Acesso em: 05 fev 2022.

JUNGES, A. H.; FONTANA, D. C.; ANZANELLO, R.; 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.

MERZLYAN, M. N et al. Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. **Physiologi Plantarum**, Lund, v. 106, n. 1, p.135-141, 1999.

MICASENSE. **Micasense RedEdge Multispectral Camera TM3**. User Manual. Seattle: Micasense, 2015, 33p.

MOLIN, J. P.; AMARAL, L. R.; COLAÇO, A. F. **Agricultura de Precisão**. 1 ed. São Paulo: Oficina de Textos. 2015.

PEDRALLI, L. D. **Aplicação de sensor multispectral a bordo de vant na determinação de graus de severidade de *Erwinia psidii* em *Eucalyptus urograndis***. 2017. 91 f. Dissertação (Mestrado em Engenharia Florestal), UFSM, Santa Maria, 2017.

REN, S.; CHEN, X.; NA, S. Assessing plant senescence reflectance index-retrieved vegetation phenology and its spatiotemporal response to climate change in the Inner Mongolian Grassland. **International Journal of Biometeorology**, v. 61, n. 4, p. 601-612, 2017.

TEIXEIRA, A. L. S. **Correlação entre índices espectrais de verdor, umidade e senescência e ocorrências de queimadas no Parque Nacional de Brasília**. 2020. 93 f. Dissertação (Mestrado em Geociências Aplicadas)—Universidade de Brasília, Brasília, 2020.

VINÍCOLA VELHO AMÂNCIO. **Velho Amâncio**. Quem somos. Disponível em: <<https://velhoamancio.com.br/quem-somos>>. Acesso em 07 jan 2022.

# DESEMPENHO DE SENSOR XRF PARA PREDIÇÃO DE MICRONUTRIENTES E SULFATO EM SOLOS TROPICAIS DE SÃO PAULO

Mateus Silva Gelain<sup>1,2</sup>; Larissa Cardoso<sup>1,2</sup>; Carlos Roberto Pinheiro Junior<sup>3</sup>; Tiago Rodrigues Tavares<sup>4</sup>; Jose Paulo Molin<sup>5</sup>

<sup>1</sup>Engº Agrônomo, Graduando - Lab. de Agricultura de Precisão, ESALQ, USP, Piracicaba - SP. mateus.gelain@usp.br / (14) 9 9758-3056; <sup>2</sup>Engº Agrônomo, Graduando - Departamento de Biossistemas, ESALQ, USP, Piracicaba - SP; <sup>3</sup>Engº Agrônomo, Doutorando - Departamento de Solos, UFRRJ, Seropédica RJ; <sup>4</sup>Engº Agrônomo, Pesquisador Pós-Doc - Lab. de Instrumentação Nuclear, CENA, USP, Piracicaba SP; <sup>5</sup>Engº Agrícola, Professor - Departamento de Eng. de Biossistemas, ESALQ, USP, Piracicaba SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Sensores de fluorescência de raios X (XRF) permitem verificar teores totais de micronutrientes e enxofre, sendo uma possível alternativa para o diagnóstico rápido dos teores disponíveis desses nutrientes. Além disso, trabalhos em solos tropicais são incipientes nessa área. Neste sentido, este trabalho objetivou avaliar o desempenho de um sensor XRF para a predição dos teores disponíveis de Fe, Mn, Zn, B, Cu e sulfato em solos tropicais do estado de São Paulo. Para isso, utilizaram um total de 137 amostras de solo, coletadas de 0 a 20 cm de profundidade, em cinco talhões agrícolas diferentes. Modelos preditivos foram calibradas e validados utilizando regressão linear múltipla. A tecnologia propiciou predições satisfatórias para S-SO<sub>4</sub><sup>2-</sup>, Mn, B, Zn e Fe (razão do desempenho pela distância interquartil (RPIQ)) de 2,11; 1,54; 2,56; 1,86 e 1,55, respectivamente), enquanto para os micronutrientes Cu apresentaram desempenho ruim (RPIQ < 1,40). Em suma, para a maioria dos micronutrientes avaliados é possível predições satisfatórias usando o sensor XRF, indicando que este sensor pode ser usado como uma alternativa mais rápida para o diagnóstico de micronutrientes no solo. Futuros trabalhos devem ser direcionados para o aprimoramento de modelos preditivos usando uma quantidade maior de dados.

**PALAVRAS-CHAVE:** Sensoriamento proximal do solo; Modelos de predição; Teor elementar

## XRF SENSOR PERFORMANCE FOR MICRONUTRIENT AND SULFUR PREDICTION IN TROPICAL SOILS OF SÃO PAULO

**ABSTRACT:** X-ray fluorescence (XRF) sensors allow checking total levels of micronutrients and sulfur, being a possible alternative for the rapid diagnosis of available levels of these nutrients. Furthermore, work on tropical soils is incipient in this area. In this sense, this work aimed to evaluate the performance of an XRF sensor for the prediction of available Fe, Mn, Zn, B, Cu and sulfate contents in tropical soils in the state of São Paulo. For this, they used a total of 137 soil samples, collected from 0 to 20 cm in depth, in five different agricultural plots. Predictive models were calibrated and validated using multiple linear regression. The technology provided satisfactory predictions for S-SO<sub>4</sub><sup>2-</sup>, Mn, B, Zn and Fe (ratio of performance to interquartile distance (RPIQ)) of 2.11; 1.54; 2.56; 1.86 and 1.55, respectively), while the micronutrients Cu showed poor performance (RPIQ < 1.40). In summary, for most micronutrients evaluated, satisfactory predictions are possible using the XRF sensor, indicating that this sensor can be used as a faster alternative for the diagnosis of micronutrients in soil. Future research should be directed towards improving predictive models using a larger amount of data.

**KEYWORDS:** Proximal soil sensing; Prediction models; Elemental content

**INTRODUÇÃO:** Abordagens e tecnologias de Agricultura de Precisão são promissoras para atender os desafios globais da agricultura do século XXI, alinhando técnicas de produção agrícola que permitem combinar retorno econômico com conservação ambiental (MOLIN et al., 2015). A gestão localizada de fertilizantes, com aplicação da quantidade adequada no local correto, faz parte dos fundamentos de boas práticas para uso eficiente de fertilizantes (BRUULSEMA et al., 2008). Neste sentido, o diagnóstico de atributos do solo via sensores é uma alternativa para incrementar a densidade espacial de informações sobre a

fertilidade de talhões agrícolas, viabilizando mapeamentos mais fidedignos que as abordagens tradicionais que utilizam grades amostrais com densidade espacial de dados limitada (MOLIN et al., 2019). Em consonância, sensores de fluorescência de raios X (XRF) têm recebido atenção dentro da comunidade de sensoriamento próximo do solo por ser uma técnica versátil em relação ao preparo de amostra e que permite análises práticas e rápidas. Além disso, ela permite obter informações sobre a constituição dos elementos químicos presentes na amostra e, com isso, inferir sobre seus atributos de fertilidade (SILVA et al. 2021). Trabalhos recentes têm mostrado o potencial do XRF para avaliação de atributos texturais (ANDRADE et al., 2020), macronutrientes (TEIXEIRA et al., 2018) e outros atributos químicos (e.g., saturação de bases, capacidade de troca catiônica, etc) (SILVA et al., 2017) em solos tropicais brasileiros, mas poucos trabalhos exploraram seu potencial para a predição de micronutrientes. Avaliando solos tropicais brasileiros do estado de Minas Gerais, Andrade et al (2020) obtiveram desempenhos de superfície razoáveis e bons para predição de Cu ( $R^2 = 0,68$ ), Mn ( $R^2 = 0,86$ ), Zn ( $R^2 = 0,68$ ), Fe ( $R^2 = 0,07$ ), B ( $R^2 = 0,36$ ). LIMA et al. (2019) analisaram solos agricultáveis do cerrado obtendo valores de predição de Mn ( $R^2=0,51$ ) e Cu ( $R^2=0,69$ ). Com o melhor de nosso conhecimento, os trabalhos apresentados acima foram os únicos a avaliar micronutrientes em solos tropicais brasileiros, fazendo-se necessário mais trabalhos em solos tropicais para subsidiar a aplicação desse sensor para o diagnóstico de micronutrientes e sulfato. Assim, o objetivo deste trabalho é avaliar o desempenho de um sensor portátil de XRF para predição dos micronutrientes Fe, Mn, Zn, B e Cu e do sulfato em solos do estado de São Paulo, de modo a avançar no entendimento do potencial dessa ferramenta para diagnóstico da fertilidade de solos tropicais.

**MATERIAIS E MÉTODOS: MATERIAL E MÉTODOS:** Foram utilizadas 137 amostras de solo, oriundas de áreas agrícolas dos municípios de Dois Córregos (designada neste estudo como área F), Monte Azul (designada área G), Patrocínio Paulista (designada área H), Coronel Macedo (designada área I), e Torrinha (designada área K), todos no estado de São Paulo. Foi utilizado um total de 10 amostras da área F, 6 amostras da área G, 45 amostras da área H, 50 amostras da área I e 26 amostras da área K. Todas as amostras foram coletadas na profundidade de 0-20 cm. Os teores dos micronutrientes Fe, Mn, Zn, B e Cu foram determinados utilizando solução ácida de etilenodiaminotetraacético (EDTA); e os teores de sulfato ( $S-SO_4^{2-}$ ) foram determinados via extração com água (Teixeira et al., 2017). Estes métodos, os quais foram utilizados como referência para os modelos preditivos via XRF, foram conduzidos em um laboratório comercial de análises de solo. As análises de XRF foram realizadas utilizando o equipamento portátil Tracer III-SD (Bruker AXS, Madison, WI, EUA). Esse equipamento foi configurado para operar com tubo de raios X a 35 kV de tensão e 7  $\mu$ A de corrente. As análises foram conduzidas sob pressão atmosférica, sem uso de filtros e com tempo de análise de 30 s. Modelos de regressão linear multivariada foram calibrados utilizando 70% das amostras ( $n=96$ ) e validados nos 30% restantes ( $n=41$ ). Para manter subconjuntos de amostras com amplitude de variância comparáveis dos atributos a serem preditos, essa divisão foi realizada através do método de Kennard-Stone (KENNARD; STONE, 1969). O desempenho dos modelos foi avaliado pelo coeficiente de determinação ( $R^2$ ), raiz do erro quadrático médio (RMSE), razão do desempenho pela distância interquartil (RPIQ) (BELLON-MAUREL et al., 2010) e o desvio porcentual relativo (RPD) (CHANG et al., 2001). Os modelos foram implementados através do software The Unscramble (Camo AS, Oslo, Noruega). Os valores de RPIQ foram interpretados seguindo as seguintes classes: modelos excelentes para  $RPIQ \geq 2,5$ , modelos muito bons para  $RPIQ < 2,5$  e  $RPIQ \geq 2,0$ , modelos bons para  $RPIQ < 2,0$  e  $RPIQ \geq 1,7$ , modelos razoáveis para  $RPIQ < 1,7$  e  $RPIQ \geq 1,4$  e modelos ruins  $RPIQ < 1,4$ .

**RESULTADOS E DISCUSSÃO: RESULTADOS E DISCUSSÃO:** Análises de estatística descritiva foram aplicadas aos dados de calibração e validação para verificar se ambos conjuntos são equiparáveis em termos de amplitude e variação (Tabela 1). Essa característica é importante para avaliação da qualidade de modelos preditivos, pois divergências nos conjuntos de calibração e validação podem deteriorar o desempenho do modelo avaliado, o que não será relacionado ao desempenho do sensor.

TABELA 1. Estatística descritiva dos atributos químicos do solo para o conjunto de calibração (CAL;  $n = 96$ ) e validação (VAL,  $n = 41$ ). **Descriptive statistics of soil chemical attributes for the calibration (CAL;  $n = 96$ ) and validation (VAL,  $n = 41$ ) set.**

Fe	Mn	Zn	S-SO <sub>4</sub> <sup>2-</sup>	B	Cu
----	----	----	---------------------------------	---	----

	mg kg <sup>-1</sup>		mg kg <sup>-1</sup>		mg kg <sup>-1</sup>		g kg <sup>-1</sup>		mg kg <sup>-1</sup>		mg kg <sup>-1</sup>	
	CAL	VAL	CAL	VAL	CAL	VAL	CAL	VAL	CAL	VAL	CAL	VAL
Média	38,01	48,56	6,52	10,75	1,40	2,56	8,78	16,44	0,27	0,34	1,09	2,07
Mediana	35,00	45,00	3,65	9,00	0,70	1,90	5,00	15,00	0,20	0,37	0,70	1,70
Desvio padrão	22,08	27,16	8,32	8,11	1,62	2,17	10,03	13,21	0,14	0,15	1,08	1,89
Mínimo	9,00	9,00	1,10	1,10	0,20	0,30	0,00	0,00	0,11	0,13	0,20	0,10
Máximo	122,00	122,00	51,30	38,70	10,50	9,90	49,00	46,00	0,60	0,75	7,10	6,90

O desempenho dos modelos preditivos calibrados neste trabalho está apresentado na Tabela 1. De maneira geral, ao observar os resultados sobre o conjunto de validação foi observado um desempenho satisfatório ( $RPIQ \geq 1,4$ ) para todos os atributos avaliados, com exceção ao Cu que apresentou  $RPIQ = 1,36$ . Os melhores modelos foram obtidos para B ( $RPIQ = 2,56$  e  $R^2 = 0,55$ ), seguido de sulfato ( $RPIQ = 2,11$  e  $R^2 = 0,42$ ), Zn ( $RPIQ = 1,86$  e  $R^2 = 0,66$ ), Fe ( $RPIQ = 1,55$  e  $R^2 = 0,23$ ), seguido de Mn ( $RPIQ = 1,54$  e  $R^2 = 0,53$ ) e Cu ( $RPIQ = 1,36$  e  $R^2 = 0,50$ ). Os desempenhos para predição de B e Fe observados neste trabalho foram maiores que os reportados por Andrade et al. (2020), que observaram  $R^2$  de 0,07 para Fe e de 0,36 para B. Por sua vez, os autores observaram desempenhos preditivos melhores para Mn e Cu, com  $R^2$  de até 0,58 e 0,69, e desempenho relativamente semelhante para Zn, com  $R^2$  de 0,68.

Tabela 2. Desempenho obtido nos conjuntos de calibração e validação para predição dos atributos do solo avaliados utilizando dados do sensor XRF associados a regressão linear múltipla. **Performance obtained in the calibration and validation sets for prediction of soil attributes evaluated using XRF sensor data associated with multiple linear regression.**

	Fe		Mn		Zn		S-SO <sub>4</sub> <sup>2-</sup>		B		Cu	
	mg kg <sup>-1</sup>		mg kg <sup>-1</sup>		mg kg <sup>-1</sup>		g kg <sup>-1</sup>		mg kg <sup>-1</sup>		mg kg <sup>-1</sup>	
	CAL	VAL	CAL	VAL	CAL	VAL	CAL	VAL	CAL	VAL	CAL	VAL
<b>R<sup>2</sup></b>	0,59	0,23	0,86	0,53	0,66	0,66	0,87	0,42	0,86	0,55	0,89	0,50
<b>RMSE<sup>1</sup></b>	14,13	23,90	3,08	6,24	0,94	1,39	3,56	10,45	0,05	0,10	0,36	1,40
<b>RMSE%<sup>2</sup></b>	37,17	49,21	47,30	58,08	66,96	54,56	40,54	63,54	18,73	29,92	32,74	67,70
<b>RPD<sup>3</sup></b>	1,56	1,14	2,70	1,30	1,72	1,56	2,82	1,27	2,68	1,48	3,02	1,35
<b>RPIQ<sup>4</sup></b>	1,98	1,55	1,88	1,54	1,38	1,86	3,51	2,11	4,62	2,56	3,08	1,36

1. Raiz do erro quadrático médio 2. RMSE em porcentagem 3. Desvio porcentual relativo 4. Razão do desempenho pela distância interquartil

Os modelos preditivos de Fe, Mn, B, Cu e sulfato apresentaram uma redução relativamente alta de desempenho ao compararmos o conjunto de calibração e validação com o de calibração, e.g., B reduziu seu  $R^2$  de 0,86 para 0,55 e o Cu de 0,89 para 0,50. Essa redução deve estar relacionada ao maior erro observado para amostras com teores altos no conjunto de validação, uma vez que a dispersão de pontos de amostras com teores mais baixos apresenta-se próxima à linha 1:1 (Figura 1). Neste sentido, duas alternativas podem ser sugeridas para trabalhos futuros: (i) aumentar o número de amostras com teores altos para a calibração de modelos e (ii) utilizar modelos preditivos mais sofisticados (e.g., modelos computacionais) para tentar capturar as relações não lineares.

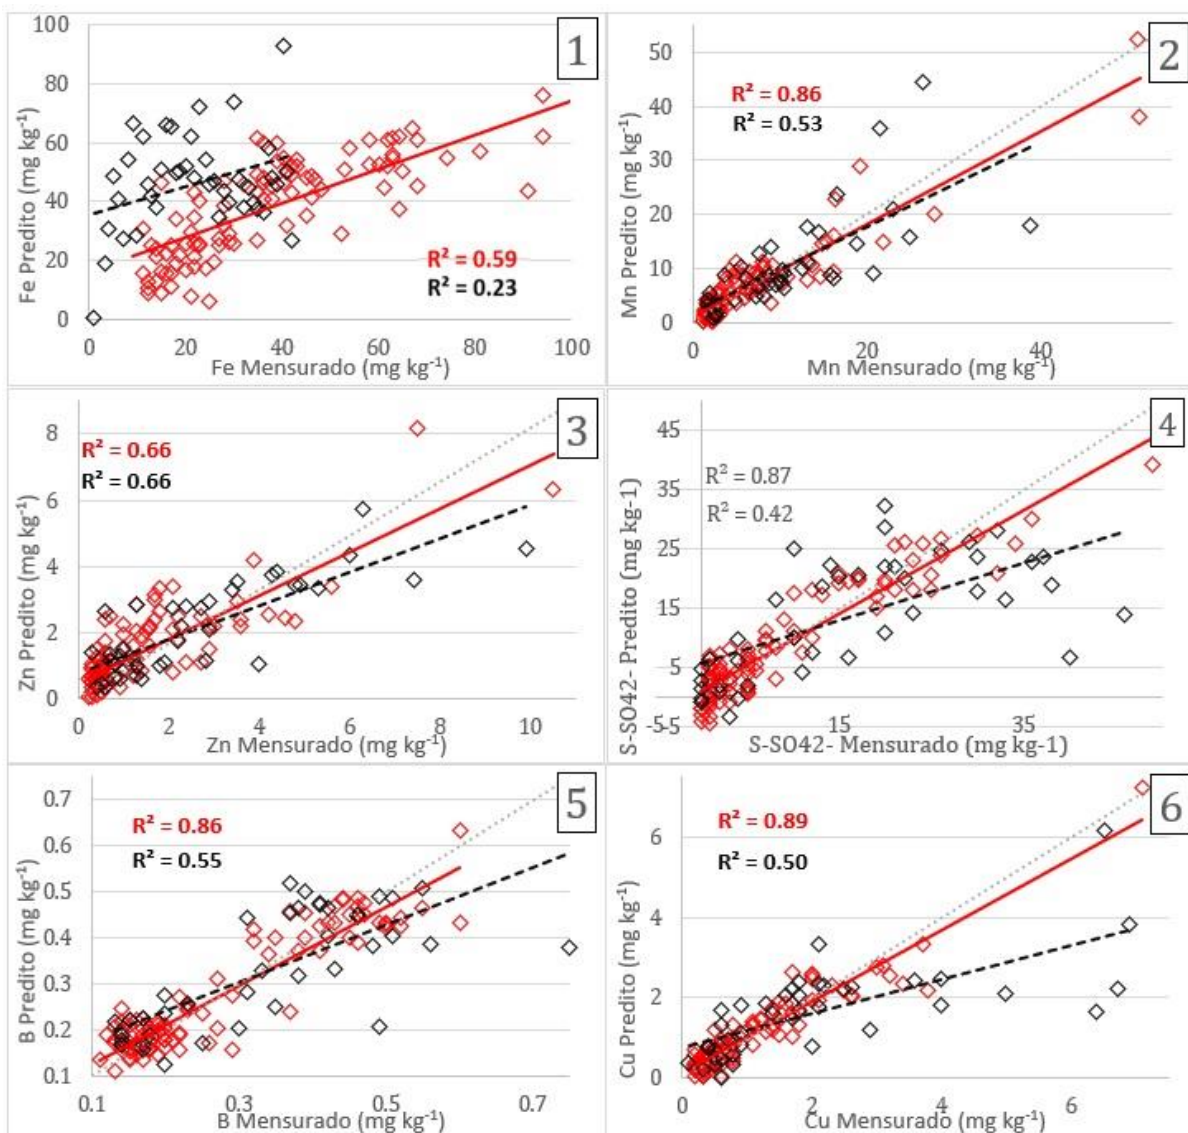


FIGURA 1. Dispersão do modelo de predição com calibração(vermelho) e validação(preto) com cálculos de R<sup>2</sup> de mensuração de XRF e atributos químicos do solo. **Dispersion of the prediction model with calibration (red) and validation (black) with R<sup>2</sup> calculations of XRF measurement and soil chemical attributes.**

A Tabela 3 mostra os coeficientes betas padronizados dos modelos de predição calibrados, indicando as variáveis com maior importância de cada um dos modelos. Observamos que os modelos de Mn e Zn apresentaram as linhas de emissão desses elementos como variáveis mais importantes, indicando a existência de uma relação entre teores totais e disponíveis destes elementos nas amostras analisadas. Os modelos de Fe e Cu, apresentaram com variáveis mais importantes as linhas de emissão do K e do Si, para o modelo de Fe, e as linhas de emissão do K e do Cr, para o modelo de Cu. Todavia, embora as linhas de emissão do Fe e do Cu não tenham apresentado maior importância para a predição desses modelos, ambas apresentaram coeficientes betas com valores intermediários (1,51 para Fe-K $\alpha$ , no modelo de Fe, e 3,13 para Cu-K $\alpha$ , no modelo de Cu), indicando uma importância secundária na calibração dos modelos. Por sua vez, os modelos de sulfato e B foram preditos utilizando variáveis secundárias, i.e., sem relação direta com o elemento de interesse. O modelo de sulfato apresentou as linhas de emissão do Zn e do Ca como principais variáveis, tendo importância baixa para a linha de emissão do S; e o modelo de B teve as linhas de emissão do Mn e os espalhamento Rh Compton-K $\alpha$  como variáveis explicativas mais importantes. Linhas de emissão de B em amostras de solo são dificilmente detectadas com sistemas portáteis de XRF, devido a seu baixo número atômico ( $Z = 5$ ) que promove uma energia de fluorescência muito baixa (B-K $\alpha = 0,18$  keV), a qual é praticamente toda atenuada pelo efeito matriz de amostras de solo (WEINDORF; Chakraborty, 2020). A linha de emissão do S também apresenta características semelhantes, embora tenha energia de fluorescência mais alta que o do B (S-K $\alpha = 2,31$  keV),

este elemento também sofre com os efeitos de atenuação exercidos pelo efeito matriz presente em amostras de solo, tornando difícil sua avaliação quando se encontra em níveis de concentração mais baixos.

TABELA 3. Importância das variáveis do sensor de fluorescência de raios X (XRF) para a predição dos atributos de fertilidade do solo estudados. Os valores apresentados correspondem aos coeficientes beta padronizado obtido na calibração das regressões. **Importance of X-ray fluorescence (XRF) variables for the prediction of studied soil fertility attributes. The values presented correspond to the standardized beta coefficients obtained in the regressions calibration.**

	Fe	Mn	Zn	S-SO <sub>4</sub> <sup>2-</sup>	B	Cu
Al-K $\alpha$	-2,05	-0,24	1,19	2,53	1,67	1,31
Si-K $\alpha$	-3,14	-0,45	1,29	1,75	1,83	-0,05
P-K $\alpha$	0,82	1,53	0,90	2,39	-0,96	1,13
S-K $\alpha$	0,70	0,65	0,38	1,26	0,38	-0,54
K-K $\alpha$	3,57	2,73	2,40	-0,43	3,37	7,35
Ca-K $\alpha$	-2,27	-2,95	-0,44	-3,06	0,88	-1,97
Ti-K $\alpha$	-1,52	-1,14	-0,72	1,18	-1,70	-1,46
Cr-K $\alpha$	0,44	0,64	1,88	1,03	2,66	4,01
Mn-K $\alpha$	-0,89	10,08	-0,30	-1,19	-3,95	2,33
Fe-K $\alpha$	1,51	-1,74	-0,17	1,01	-1,80	-0,66
Ni-K $\alpha$	-0,03	1,06	0,47	1,55	0,99	1,67
Cu-K $\alpha$	-2,83	1,11	-1,47	-2,51	1,85	3,13
Zn-K $\alpha$	1,52	2,28	5,64	6,48	1,95	0,76
Zr-K $\alpha$	2,42	-0,28	-0,96	-2,70	0,89	-3,52
Thom-K $\alpha$	-0,96	1,61	0,51	-0,73	1,16	1,61
Thom-La	-0,66	1,41	1,44	-0,98	2,77	1,70
Com-K $\alpha$	1,65	-1,35	-0,68	-2,10	-3,78	-2,15

\*Classificação gradual por desvio padrão referente a cada nutriente onde vermelho representa os valores negativos, branco valores próximos a zero e azul valores positivos.

**CONCLUSÃO: CONCLUSÃO:** A modelagem de dados do sensor XRF aplicada em amostras de solos de cinco áreas agrícolas diferentes do estado de São Paulo apresentou predições ruins para Cu (RPIQ = 1,36 e R<sup>2</sup> = 0,50), predições razoáveis para Fe (RPIQ = 1,55 e R<sup>2</sup> = 0,23) e Mn (RPIQ = 1,54 e R<sup>2</sup> = 0,53), boas para Zn (RPIQ = 1,86 e R<sup>2</sup> = 0,66) e excelentes para sulfato (RPIQ = 2,11 e R<sup>2</sup> = 0,42) e B (RPIQ = 2,56 e R<sup>2</sup> = 0,55). As predições de Mn e Zn utilizaram a linha de emissão destes elementos como variáveis mais importantes, indicando relações diretas entre os teores totais e extraíveis destes elementos. Enquanto, que as demais predições apresentaram caráter indireto, i.e., utilizando as linhas de emissão de elementos secundários para a predição. De maneira geral, os modelos apresentaram perda de acurácia ao avaliar amostras com teores elevados dos nutrientes estudados, havendo a necessidade de incrementar o número dessas amostras com essas concentrações em trabalho futuros, bem como avaliar modelos de predição não lineares que podem apresentar melhores desempenhos que os reportados neste trabalho. Os resultados obtidos no presente trabalho mostram o potencial do XRF para ser utilizado como um método rápido para diagnósticos satisfatórios de micronutrientes e aponta perspectivas para futuros trabalhos que desejam aprofundar neste tema.

**AGRADECIMENTOS:** Agradecemos à empresa Ribersolo Laboratório de Análises Agrícolas, pela disponibilização das amostras e análises de referência, bem como à FAPESP pelo suporte financeiro ao T.R.T. (processo nº 2020/16670-9).

## 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.
- BRUULSEMA, T. et al. Global framework for fertilizer BMPs. **Better Crops**, v. 92, p. 13-15, 2008.
- 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, n.2, p.480-490, 2001.
- Kennard, R.W.; Stone, L.A. computer aided design of experiments. **technometrics**, v.11, n.1, p.137-148, 1969.
- LIMA, T. M. de et al. Elemental analysis of Cerrado agricultural soils via portable X-ray fluorescence spectrometry: Inferences for soil fertility assessment. **Geoderma**, [S.I.], v. 353, p. 264-272, Nov. 2019.
- MOLIN, José Paulo; AMARAL, Lucas Rios do; COLAÇO, André Freitas. Agricultura de precisão. [S.l.: s.n.], 2015.
- MOLIN, J.P. et. al. Sensor systems for mapping soil fertility attributes: Challenges, advances, and perspectives in brazilian tropical soils. *Engenharia Agrícola*, 39, pp.126-147, 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. Multiple linear regression and random forest to predict and map soil properties using data from portable x-ray fluorescence spectrometer (pXRF). **Ciência e Agrotecnologia**, v.41, n.6, p.648-664, 2017.
- SILVA, S.H.G., Ribeiro, B.T., Guerra, M.B.B., de Carvalho, H.W.P., Lopes, G., Carvalho, G.S., Guilherme, L.R.G., Resende, M., Mancini, M., Curi, N. and Rafael, R.B.A., 2021. pXRF in tropical soils: Methodology, applications, achievements and challenges. *Advances in Agronomy*, 167, pp.1-62.
- 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. **Ciência e Agrotecnologia**, v.42, n.5, p.501-512, 2018.
- TEIXEIRA, P.C.; DONAGEMMA, G.K.; FONTANA, A.; TEIXEIRA, W.G. **Manual de métodos de análise de solo**. Embrapa, Brasília, 2017.
- 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.



# SENSORES DE DISTÂNCIA PARA MEDIDAS DE ALTURA DO DOSSEL FORRAGEIRO

Orlando Daniel Masnello<sup>1</sup>; José Paulo Molin<sup>2</sup>

<sup>1</sup>Eng<sup>o</sup> Agrônomo, Mestrando - Laboratório de Agricultura de Precisão, ESALQ, USP, Piracicaba-SP. danielmasnello@gmail.com / (19) 9 9252-8063; <sup>2</sup>Eng<sup>o</sup> Agrícola, Professor - Laboratório de Agricultura de Precisão, ESALQ, USP, Piracicaba-SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Medidas de altura do dossel forrageiro são necessárias para a otimização do uso de pastagens em sistemas pecuários. Com base nessas medidas é possível identificar os melhores momentos para realização do pastejo ou corte da forragem. Diversos métodos são encontrados para realização dessa medida, incluindo sensores de distância, que são capazes de mensurar a altura do dossel com base na posição do sensor e a distância mensurada. Neste trabalho buscou-se avaliar uma metodologia de medidas de altura do dossel forrageiro em pastos de capim coast cross, utilizando os sensores de distância sonar e LiDAR, coletando dados de um deslocamento sobre o dossel para estimar a altura média, a qual foi comparada com medidas pelo método tradicional. Os resultados encontrados foram de  $R^2 = 0,96$  para os dois sensores avaliados, com um RMSE = 0,03 m. Assim infere-se que o método avaliado pode ser utilizado em medidas de altura do dossel. Estudos posteriores poderão avaliar a efetividade desta metodologia para medidas em movimento visando à automação do processo.

**PALAVRAS-CHAVE:** Sensoriamento Proximal; Sensores de Distância; Pastagens

## USE OF SONAR AND LIDAR DISTANCE SENSORS IN FORAGE CANOPY HEIGHT MEASUREMENTS

**ABSTRACT:** Measures of forage canopy height are an important tool for optimizing the use of pastures in livestock systems, based on these measures it is possible to identify the best times to carry out grazing or forage cutting. Several methods are found to perform this type of measurement, among these methods are the distance sensors, which are able to measure the canopy height based on the position of the sensor and the measured distance. The work in question sought to evaluate a methodology for measuring forage canopy height in coast cross grass pastures, using two distance sensors, sonar and LiDAR, collecting data from a displacement over the canopy to estimate its average height, which was compared with measurements by the traditional method. The results found were  $R^2 = 0.96$  for the two sensors evaluated, with an RMSE = 0.03 m. With this it can be understood that the evaluated method can be used in canopy height measurements. Further studies can assess the effectiveness of this methodology for measurements in motion.

**KEYWORDS:** Proximal Sensing; Distance Sensors; Pastures

**INTRODUÇÃO:** O monitoramento de variáveis biométricas de pastagens é uma importante ferramenta para o desenvolvimento de uma pecuária mais eficiente e sustentável. A partir delas é possível adequar a oferta de forragem à demanda animal de maneira mais assertiva (Pedreira, 2002). Uma das estratégias mais utilizadas no monitoramento é a mensuração da altura do dossel forrageiro, que pode indicar o momento de entrada dos animais, ou corte da forragem, e o tempo de permanência, a partir da altura residual. Por ser uma medida de fácil obtenção, ela é amplamente utilizada tanto na pesquisa quanto em ambientes de produção (Silva e Júnior, 2007). Várias técnicas de medida de altura do dossel forrageiro vem sendo propostas, baseadas no uso de sensores capazes de realizar tais medidas, reduzindo a mão de obra empregada e aumentando a capacidade de coleta de dados, que por sua vez possibilita análises mais complexas, como por exemplo medidas espacializadas de altura do dossel (Fricke et al., 2011). Os principais tipos de sensores utilizados para medidas de altura do dossel forrageiro são sensores de distância baseados no princípio do tempo de voo, a qual mede o tempo de retorno de um sinal ao sensor após refletido por um objeto qualquer. Dentre eles estão os sensores ultrassônicos, que emitem ondas sonoras, e sensores LiDAR (Light Detection and Ranging), que emitem feixes

de luz (Safari et al., 2016; Colaço et al., 2018). Este trabalho objetivou avaliar o uso de sensores de baixo custo, sonar e LiDAR, para medidas de altura do dossel forrageiro de pastos de *Cynodon dactylon* cv. coast-cross.

**MATERIAIS E MÉTODOS:** O experimento foi realizado durante a primavera de 2021, em um piquete de capim coast cross submetido a pastejo rotativo de ovinos, em área experimental da Escola Superior de Agricultura “Luiz de Queiroz” (ESALQ) pertencente ao campus de Piracicaba da Universidade de São Paulo (USP). Uma estrutura metálica foi desenvolvida para medidas de altura do dossel forrageiro com uso dos sensores e medidas com uso de bastão graduado e folha plástica (Mannetje, 2000) em um mesmo ponto. Uma haste metálica com fita métrica foi utilizada para as medidas manuais e uma barra metálica perpendicular foi fixada na haste, onde os sensores foram acoplados, de modo que essa barra permitisse o movimento linear dos sensores sobre o dossel (Figura 1). Os sensores utilizados foram sensor ultrassônico Hc-Sr04 (OSEPP Electronics, Canadá), que apresenta ângulo de abertura de 15° e mensura distâncias entre 0,02m e 4m. A mensuração é prejudicada em materiais com isolamento acústico e a distância máxima indicada para seu uso é reduzida para 3m em medidas ao ar livre. E o sensor TFmini-LiDAR (Seeed Studio, China), que possui ângulo de abertura de 2,3° e mensura distâncias entre 0,03m e 12m. A mensuração é prejudicada em casos extremos, com luminosidade acima de 100 lux, e a distância máxima indicada para seu uso é reduzida para 9m para medidas ao ar livre. Foi estabelecida uma frequência de 100 hz para a coleta de dados, e as medidas de altura do dossel foram dadas pela diferença entre a altura dos sensores até o solo e a distância mensurada dos sensores sobre o dossel.

Foram estabelecidos 30 pontos de coleta, elencados em cinco categorias, sendo “1” os pontos de menor altura e “5” os pontos de maior altura do dossel. Para cada ponto foram realizadas medidas com os sensores coletando dados de maneira contínua em um deslocamento de 0,5m (Figura 1). O deslocamento foi realizado manualmente, coletando em média mil pontos de distância entre os sensores e o dossel forrageiro para cada ponto de calibração, os quais foram posteriormente processados para estimativas de altura do dossel média para cada ponto de calibração. O deslocamento foi proposto para estimar a altura média em uma faixa de dossel, uma vez que medidas de maneira pontual podem representar uma área específica não representativa da altura média da população de plantas ao redor do ponto. Desta forma, o conjunto de dados em uma faixa de 0,5m pode representar tanto as variações dentro de cada ponto como também a média de altura do dossel, podendo ser comparadas com os métodos tradicionais de medidas de altura do dossel forrageiro manuais. Os dados dos sensores foram filtrados excluindo manualmente apenas os pontos extremos, maiores que a altura dos sensores até o solo e menores que zero.

Após as medidas realizadas com os sensores foi medida a altura com uso de folha plástica e bastão graduado em três pontos dentro da faixa de 0,5m medida pelos sensores. A média dos valores das medidas dos sensores foi comparada com a média das três medidas com folha plástica, para cada ponto, por meio de regressão linear simples, usando como base coeficiente de determinação ( $R^2$ ) e Raiz do Erro Quadrático Médio (RMSE).




Figura 1. Estrutura metálica utilizada para acoplamento dos sensores e esquematização do movimento realizado para coleta dos dados pelos sensores em uma faixa de 0,5 m sobre o dossel forrageiro. **Metallic structure used to move the sensors and scheme of collection carried out in a range of 0.5 m over the forage canopy.**

**RESULTADOS E DISCUSSÃO:** Os valores de regressão entre altura obtida pelos sensores e altura obtida pelo método tradicional foram próximos para os dois sensores (Figura 2), com o sonar apresentando melhores coeficientes de determinação ( $R^2$ ) e menor RMSE em comparação com o sensor LiDAR. É possível observar que os sensores medem a altura em uma região inferior do dossel quando comparados com a folha plástica utilizada nas medidas pelo método tradicional. Mesmo que em medidas muito próximas.




Figura 2. Regressão linear entre os valores de altura obtidos pelo método tradicional e os valores obtidos pelos sensores em pastos de capim coast-cross. **Linear regression between the height values by the traditional method and the values obtained by the sensors in coast-cross grass pastures.**

Os valores encontrados são superiores aos melhores valores observados na literatura com uso de sensoriamento proximal para estimativas de altura do dossel forrageiro. Obanawa et al. (2020) obtiveram valores de  $R^2= 0,93$  com uso de LiDAR de varredura em pastos de azevém-italiano (*Lolium multiflorum*) no Japão, utilizando resolução espacial de 0,02 m para o modelo de cobertura de superfície e estimando a altura do dossel a partir da subtração entre o modelo de cobertura de superfície do dossel e o modelo do terreno, obtido pós corte de forragem. Grüner et al. (2019) encontraram valores de até  $R^2= 0,84$  utilizando fotogrametria para estimativa de altura de plantas em pastos consorciados de leguminosas de clima temperado, na Alemanha.

Com isso, entende-se que o uso dos sensores pode ser indicado para a mesma finalidade de medidas tradicionais de altura do dossel, as quais se correlacionam com biomassa (Mannetje, 2000) e interceptação luminosa do dossel (Silva e Junior, 2007), fundamentais para técnicas de manejo de pastejo. Futuros estudos poderão avaliar esta metodologia em outras cultivares de plantas forrageiras tropicais, bem como para medidas em movimento.

**CONCLUSÃO:** O uso dos sensores LiDAR e Sonar em medidas de altura do dossel forrageiro a partir da média dos dados coletados em deslocamento apresentou boa correlação com medidas pelo método de folha plástica e bastão graduado, podendo assim ser utilizado para esta finalidade em pastos de capim coast cross.

#### REFERÊNCIAS

- COLAÇO, A. F., MOLIN, J. P., ROSELL-POLO, J. R., & ESCOLÀ, A. Application of light detection and ranging and ultrasonic sensors to high-throughput phenotyping and precision horticulture: current status and challenges. **Horticulture research**, v. 5, n. 1, p. 1-11, 2018.
- GRÜNER, E.; ASTOR, T.; WACHENDORF, M. Biomass prediction of heterogeneous temperate grasslands using an SfM approach based on UAV imaging. **Agronomy**, v. 9, n. 2, p. 54, 2019.
- FRICKE, T., RICHTER, F., & WACHENDORF, M. Assessment of forage mass from grassland swards by height measurement using an ultrasonic sensor. **Computers and electronics in agriculture**, v. 79, n. 2, p. 142-152, 2011.
- MANNETJE, L.T. Measuring biomass of grassland vegetation. p. 151-177. In: Mannelje, L. & Jones, R.M. (eds.) Field and laboratory methods for grassland and animal production research. 2000
- OBANAWA, H., YOSHITOSHI, R., WATANABE, N., & SAKANOUÉ, S. Portable LiDAR-Based Method for Improvement of Grass Height Measurement Accuracy: Comparison with SfM Methods. **Sensors**, v. 20, n. 17, p. 4809, 2020.
- Pedreira, C. G. S. Avanços metodológicos na avaliação de pastagens. **Reunião Anual da Sociedade Brasileira de Zootecnia**, v. 39, p. 100-150, 2002.
- SAFARI, H., FRICKE, T., REDDERSEN, B., MÖCKEL, T., & WACHENDORF, M. Comparing mobile and static assessment of biomass in heterogeneous grassland with a multi-sensor system. **Journal of Sensors and Sensor Systems**, v. 5, n. 2, p. 301-312, 2016.
- SILVA, S. C. DA; JÚNIOR, D. DO N. Avanços na pesquisa com plantas forrageiras tropicais em pastagens: características morfofisiológicas e manejo do pastejo. **Revista Brasileira de Zootecnia**, v. 36, p. 122-138, 2007.

# ESPECTROSCOPIA NIR APLICADA AO MAPEAMENTO DA VARIABILIDADE ESPACIAL DA QUALIDADE DE CANA-DE-AÇÚCAR

Lucas de Paula Corrêdo<sup>1</sup>; José Paulo Molin<sup>2</sup>

<sup>1</sup>Engenheiro Agrícola, Professor - Depto. de Agronomia, Universidade Federal de Viçosa, UFV, Viçosa ? MG. lucas.corredo@ufv.br / (31) 9 8581-8748; <sup>2</sup>Engenheiro Agrícola, Professor - Depto. de Engenharia de Biossistemas, ESALQ, USP, Piracicaba ? SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Um nova vertente tem se aberto para gestão da variabilidade espacial de lavouras agrícolas a partir de pesquisas buscando mapear a qualidade de produtos agrícolas. A cana-de-açúcar é comercializada com base em atributos de qualidade, como o teor de sólidos solúveis (Brix). Entretanto, não existe um equipamento destinado a esse fim. O objetivo dessa pesquisa foi avaliar a espectroscopia de infravermelho próximo (NIRS) como sensor proximal para estimativa de Brix e aplicações em campo. No primeiro estudo, avaliou-se o potencial da NIRS para prever e mapear o Brix em uma lavoura comercial de cana-de-açúcar. Foram desenvolvidos modelos de regressão por mínimos quadrados parciais (PLS) a partir de amostras de cana desfibrada, e utilizados para produção de mapas de qualidade de uma lavoura comercial a partir de amostras coletadas em campo. No segundo, determinou-se a melhor condição de preparo mínimo de amostras para predição de Brix a partir de NIRS. Foram avaliadas amostras de colmos inteiro, cana desfibrada e caldo cru. No terceiro, avaliou-se um método para mensurar a qualidade da cana-de-açúcar a partir de um sensor NIRS embarcado. O Brix apresentou dependência espacial moderada. Além disso, a cana desfibrada apresentou melhor potencial preditivo do atributo. Por fim, um método de transferência de calibração baseado em amostras de cana desfibrada permitiu produzir modelos para estimativa de Brix com um sensor NIR embarcado no elevador de uma colhedora.

**PALAVRAS-CHAVE:** Agricultura digital; Espectrômetro portátil; Qualidade tecnológica

## NIR SPECTROSCOPY APPLIED TO SPATIAL VARIABILITY MAPPING OF SUGARCANE QUALITY

**ABSTRACT:** New opportunities have been appearing for spatial variability management of agricultural crops from research aiming to map the quality of agricultural products. Sugarcane is marketed based on quality attributes, such as soluble solids content (Brix). However, there is no equipment designed for this purpose. This research aimed to evaluate the near-infrared spectroscopy (NIRS) as a proximal sensor for Brix estimation and field applications. In the first study, we evaluated the potential of NIRS to predict and map Brix in a commercial sugarcane crop. Partial least squares (PLS) regression models were developed from defibrated cane samples and used to produce quality maps of a commercial crop from field-collected samples. In the second, we determined the best minimum sample preparation condition for Brix prediction from NIRS. Billets, defibrated cane, and raw juice samples were evaluated. In the third, we evaluated a method to measure sugarcane quality from an on-board NIRS sensor. Brix showed moderate spatial dependence. Moreover, the defibrated cane showed a better predictive potential of the attribute. Finally, a calibration transfer method based on defibrated cane samples allowed to produce models for Brix estimation with an on-board NIR sensor on a harvester elevator.

**KEYWORDS:** Digital agriculture; Portable spectrometer; Technological quality

**INTRODUÇÃO:** Sensores para estimativa de atributos relacionados à qualidade de produtos agrícolas têm sido avaliados e implementados desde linhas de produção em setores industriais até iniciativas em âmbito de produção agrícola (WALSH *et al.*, 2020). Com aplicações avançadas no setor industrial, a espectroscopia no infravermelho próximo (NIRS) apresenta-se como a melhor alternativa devido à precisão das medições, realização de análises não destrutivas e rápidas, facilidade de operação, custo reduzido e sustentabilidade da análise (CORTÉS *et al.*, 2019). Produtos cujo valor agregado está diretamente atrelado a atributos de

qualidade, como a cana-de-açúcar, justificam o esforço para monitorar a variabilidade espacial desses parâmetros nas lavouras a fim de realizar a gestão localizada visando obter maiores retornos financeiros. Assim, o objetivo principal desse trabalho foi investigar métodos para monitorar a variabilidade espacial do teor de sólidos solúveis (Brix) da cana-de-açúcar com base em espectroscopia de infravermelho próximo (NIRS). A espectroscopia na região infravermelho próximo é uma técnica analítica de espectroscopia vibracional a partir da qual a interação da radiação ocorre principalmente através de excitação, combinações e ressonâncias de modos vibracionais fundamentais de grupos funcionais moleculares contendo átomos como C, N, O e S ligados a um átomo de hidrogênio, os principais átomos e moléculas presentes em compostos orgânicos (PASQUINI, 2018). Sensores baseados neste princípio físico foram amplamente adaptados para aplicação em linhas na produção industrial de alimentos, para mensuração de atributos de qualidade de diversas matrizes tais como amostras sólidas intactas, pastosas e fluidas (POREP; KAMMERER; CARLE, 2015). Em usinas de cana-de-açúcar são utilizados em análises de rotina para medir o teor de sacarose aparente (Pol) e concentração de sólidos solúveis (Brix) do caldo (SEXTON *et al.*, 2020). Assim, essa tecnologia tem sido objeto de estudo de diversos trabalhos aplicados à cultura da cana-de-açúcar, para aplicações em condições controladas avaliando formas de mensuração para viabilizar a tecnologia como ferramenta de mensuração para gestão da variabilidade espacial da qualidade (NAWI *et al.*, 2013; NAWI; CHEN; JENSEN, 2013; PHETPAN; UDOMPETAIKUL; SIRISOMBOON, 2018; UDOMPETAIKUL; PHETPAN; SIRISOMBOON, 2021) ou em programas de melhoramento de cana (MARAPHUM *et al.*, 2018; PHUPHAPHUD *et al.*, 2020, 2019). Entretanto, poucos estudos avaliaram a técnica de NIRS para aplicação direta em campo, com o objetivo de avaliar potencial de aplicação frente às condições hostis da colheita mecanizada para mensuração da variabilidade espacial da qualidade. Sendo assim, esse estudo teve por objetivos: (i) investigar a dependência espacial de Brix ao longo de uma lavoura comercial com predição baseada em modelos de NIRS; (ii) avaliar diferentes níveis de processamento mínimo de amostras para predição de Brix; e (iii) avaliar um método de mensuração com um sensor NIRS embarcado em uma colhedora para medições espectrais em tempo real.

**MATERIAIS E MÉTODOS:** A pesquisa foi dividida em três estudos consecutivos. No primeiro, avaliou-se o potencial da NIRS para prever e mapear o Brix em uma lavoura comercial de cana-de-açúcar. No segundo, determinou-se a melhor condição de preparo mínimo de amostras para predição de Brix a partir de NIRS. No terceiro, avaliou-se um método para mensurar a qualidade da cana-de-açúcar a partir de um sensor NIRS embarcado.

A obtenção dos dados de referência foi realizada em um laboratório de qualidade industrial, seguindo os métodos convencionais de análise de qualidade propostos pelo CONSECANA (CONSECANA, 2015). O procedimento de coleta de amostras para obtenção das leituras espectrais correspondentes aos dois primeiros estudos foi realizado simultaneamente à preparação da amostra para análise convencional de qualidade, conduzida tal como descrito:

- Uma sonda oblíqua coletou uma amostra de colmos de cana-de-açúcar na carga transportada por cada caminhão para a indústria da usina para proceder às análises convencionais (Figura 1a);
- A amostra foi moída em um desfibrador mecânico e homogeneizada em uma betoneira adaptada. Em seguida, foram coletadas amostras com 500 g da cana-de-açúcar desfibrada homogeneizada (Figura 1b);
- A amostra de 500 g foi prensada em uma prensa hidráulica sob pressão constante, a 24,5 MPa (250 kgf cm<sup>-2</sup>) durante 60 s, para obter o caldo cru para análise convencional (Figura 1c);
- O teor de sólidos solúveis (Brix) foi determinado vertendo caldo bruto em um refratômetro (RX-5000α, ATAGO Co Ltd., Tokyo, Japão).






FIGURA 1. Sequência de aquisição de cada tipo de amostra durante as etapas de preparação das amostras para análise convencional: Amostragem de colmos de cana de açúcar por sonda oblíqua no caminhão de carga (a) e colmos de cana de açúcar para medições na superfície e no corte transversal transversal (b); moagem e homogeneização da cana de açúcar e obtenção de amostra de cana desfibrada; prensagem de amostra desfibrada para extração de caldo e caldo bruto extraído (c); análise convencional (d) e obtenção de dados espectrais de cada tipo de amostra (e). **Sequence of acquisition of each sample type for during the sample preparation steps for conventional analysis: Sampling of sugarcane stalks by oblique probe in the cargo truck (a) and sugarcane stalks for surface and cross-sectional measurements (b); milling and homogenization of sugar cane and obtaining shredded cane sample; pressing of shredded sample for juice extraction and extracted raw juice (c); conventional analysis (d) and obtaining spectral data for each type of sample (e).**

Para o primeiro estudo, conduzido na safra de 2018/19, foram coletadas 350 amostras de cana desfibrada homogeneizada (Figura 1b) para desenvolvimento dos modelos de calibração. Cada amostra foi composta por três subamostras de 50 g de cana desfibrada, as quais foram submetidas a leituras espectrais, com cinco repetições, a fim de obter um espectro médio representativo. As leituras espectrais foram registradas como absorvância medida com um espectrômetro portátil AgriNIR (Dynamica Generale S.p.A., Poggio Rusco, Mantova, Itália), operando na faixa de 1100-1800 nm com resolução espectral de 10 nm. Para validação deste estudo, foram coletadas 90 amostras georreferenciadas ao longo de uma área comercial, de forma aleatória (Figura 2), provenientes de um banco de dados previamente coletado (FERRAZ *et al.*, 2019). Foram coletados quatro colmos, cortados ao nível do solo, e removidas as folhas. As amostras foram levadas ao laboratório e processadas seguindo o protocolo de análise do CONSECANA, conforme descrito anteriormente. O mesmo equipamento NIR e procedimentos de análise foram utilizados para coleta de dados de calibração e validação.

Para o segundo estudo, conduzido durante seis meses distribuídos ao longo da safra 2019/20, foram coletados três tipos de amostra. Buscou-se inserir variação dos teores nos modelos de calibração por meio de dados coletados em diferentes estações ao longo da safra (PAGANI *et al.*, 2017), de junho a dezembro. Inicialmente, após a etapa de sondagem, foram coletados três colmos selecionados aleatoriamente, seccionados e levemente limpos (Figura 1a). Em seguida, após a moagem e homogeneização, foi coletada uma subamostra de 50 g de cana desfibrada (Figura 1b). Por fim, após a prensagem, foi coletada uma subamostra de 50 mL de caldo cru (Figura 1c). As leituras foram realizadas, em triplicata, em três pontos equidistantes na casca, de acordo com método adaptador a partir do proposto por Nawi *et al.* (2013), e na secção transversal de cada colmo, conforme proposto por Nawi, Chen e Jensen (2013), e em três subamostras de cana desfibrada e caldo cru. Foram coletados 302 espectros médios para cada tipo de amostra, correspondentes a amostras coletadas em cada carga, divididas em conjunto de calibração (227 amostras, 75%) e validação (75 amostras, 25%) pelo método de Kennard-Stone (KENNARD; STONE, 1969). As leituras espectrais do segundo estudo foram obtidas como absorvância mensurada com um espectrômetro Veris vis-NIR (Veris Technologies Inc., Salina, KS, EUA), em modo de operação em bancada, operando na faixa espectral de 373 a 2222 nm, com resolução média de aproximadamente 5 nm (Figura 1e). Toda a aquisição de dados espectrais de ambos os estudos foi realizada em ambiente com temperatura controlada ( $20 \pm 5$  °C), imediatamente após a obtenção de cada amostra, com o intuito de minimizar os efeitos da degradação do açúcar por microrganismos.




FIGURA 2. Pontos de coleta de amostras georreferenciadas em lavoura comercial.

O terceiro estudo foi executado durante a safra 2020/21, em três dias consecutivos, em três áreas de uma lavoura comercial, com a cultivar CTC 4 em segundo corte. Foi desenvolvida uma plataforma para obtenção de dados espectrais com um micro-espectrômetro (microNIR 1700 spectrometer, Viavi Solutions, JDSU Corporation, Milpitas, CA) embarcado no elevador de uma colhedora de cana-de-açúcar, imediatamente antes do extrator secundário, conforme descrito por NAWI, CHEN e JENSEN (2014). Como fonte de radiação eletromagnética, foram utilizadas quatro lâmpadas halógenas (tipo AR111) com tensão de 12 V e potência de 50 W (PHETPAN; UDOMPETAIKUL; SIRISOMBOON, 2018). As lâmpadas foram montadas de forma a irradiar a região imediatamente sob o sensor. Todo o sistema embarcado foi coberto por uma caixa de aço galvanizado com o interior pintado em preto fosco, e o exterior pintado em branco, para minimizar as interferências da iluminação externa. A plataforma foi fixada ao elevador por meio de quatro amortecedores de vibração de borracha.

Antes das medições em tempo real, foi realizada a calibração do sensor NIR em condições de campo e otimização da altura em relação ao alvo. Um aumento da distância operacional poderia causar uma queda na relação sinal/ruído do espectro devido a uma diminuição da intensidade luminosa que atinge a amostra. Para isso, o tempo de integração do espectrômetro precisa ser devidamente otimizado para contabilizar a perda em intensidade fotométrica. Uma placa de sulfato de bário branco quadrado ( $\text{BaSO}_4$ ), com 0,40 m, foi utilizada como padrão de referência para calibrar o sensor, assumindo uma reflectância uniforme igual a um (100%) (MAYRINK *et al.*, 2019), enquanto uma referência escura foi obtida a partir do ambiente de medição da câmara. As luzes foram ligadas para calibração branca e desligadas para a referência escura (ambiente da câmara). A placa branca foi posicionada sobre a esteira do elevador, e a calibração foi otimizada para 50 leituras médias e tempo de integração de 35 ms (0,7 ms por ponto amostral), resultando num tempo de medição de 1,75 s para obter cerca de 50000 a 60000 contagens brutas de intensidade fotométrica, como recomendado pelo fabricante. Sendo assim, o sensor foi fixado a uma altura de 200 mm entre a janela de safira e o fundo da correia transportadora e 40 mm sobre as aletas da correia transportadora do elevador. A obtenção do posicionamento de cada espectro coletado foi realizada com um receptor GNSS SMART6-L™ (Novatel Inc., Calgary, Alberta, Canadá) com correção TerraStar-C, que permite a precisão de  $\pm 0,09$  m. O GNSS foi fixado sobre a cabine da colhedora na direção do corte de base. Todo o sistema foi alimentado pela bateria da colhedora.

A colheita foi realizada a uma velocidade de  $1 \text{ m s}^{-1}$ , e a velocidade da correia transportadora do elevador a uma velocidade de  $2 \text{ m s}^{-1}$ . O tempo de alimentação foi avaliado visualmente para correção e *offset* da posição das leituras espectrais ao centro de cada linha colhida. Durante a colheita, foram coletadas amostras aleatoriamente nas três áreas durante as medições com o sistema embarcado para desenvolvimento dos modelos de calibração e validação. Para realizar a amostragem, o transbordo avançou à frente da colhedora e a amostra foi lançada diretamente sob uma lona no solo. Em seguida, o ponto colheita foi registado com um receptor GNSS portátil (Garmin 62 s, precisão de 5 m). A amostragem foi realizada com um espaçamento mínimo de duas fileiras de cana colhida. Foram coletadas 66 amostras para as três áreas, armazenadas em sacos plásticos e enviadas para o laboratório, onde foram armazenadas em congelador a  $2 \text{ }^\circ\text{C}$  para minimizar os efeitos da degradação dos compostos orgânicos por microorganismos e analisados no dia seguinte para determinar o Brix seguindo o protocolo do CONSECANA, como descrito para os estudos anteriores. Além disso, foram adquiridos os espectros de subamostras de cana desfibrada em bancada para as mesmas 66 amostras, registrados como a média de três mensurações em cada subamostra. As amostras foram segmentadas em conjunto de calibração (47 amostras) e validação (19 amostras), compostos por 75% e 25% de amostras de cada área de coleta, respectivamente.

Diferentes técnicas de pré-processamento de dados foram aplicadas aos espectros antes da calibração. O ajuste do pré-processamento foi avaliado pelo valor mais baixo do erro quadrático médio (RMSE) de validação cruzada. Adicionalmente, para o terceiro estudo, foi aplicado o método de transferência de calibração *piecewise direct standardization* (PDS) (WANG; VELTKAMP; KOWALSKI, 1991), com o intuito de desenvolver uma matriz de correção dos espectros coletados em tempo real (JI; VISCARRA ROSSEL; SHI, 2015; NAWAR; MUNNAF; MOUAZEN, 2020). Após a realização de testes preliminares, foi pré-definida uma janela de 9 comprimentos de onda para execução do algoritmo PDS. Em seguida, os modelos de calibração foram executados baseados em regressões por mínimos quadrados parciais (PLS). Nos dois primeiros estudos, a calibração foi desenvolvida utilizando o método de *venetian blinds* com 10 *splits*, e no terceiro estudo foi utilizado o método *leave-one-out*, devido ao menor número de amostras. O ajuste do modelo PLS foi



determinado com base no menor número de variáveis latentes (LV), em que o erro quadrático médio (RMSE) de validação cruzada não foi substancialmente superior ao RMSE mínimo observado.

Para avaliação de desempenho dos modelos, nos dois primeiros estudos, além do RMSE para avaliação da acurácia, foi utilizado o coeficiente de determinação ( $R^2$ ). No terceiro estudo, também foram avaliados o RMSE relativo (RRMSE) e o desempenho para o intervalo interquartil (RPIQ).

Para o primeiro e terceiro estudo, foram realizadas análises geoestatísticas para a base de dados georreferenciados contendo valores observados e preditos por espectroscopia NIR. Os semivariogramas foram ajustados para estimar a estrutura da variação espacial, selecionados com base no menor valor de RMSE. A dependência espacial foi classificada de acordo com método descrito por Cambardella et al. (1994). Os mapas foram produzidos através da interpolação dos dados utilizando krigagem ordinária. Em seguida, os atributos de qualidade da cana de açúcar foram mapeados. A similaridade entre os mapas observado e predito, no primeiro estudo, foi avaliada por comparação visual e pelo coeficiente de correlação (COLAÇO *et al.*, 2019).

Para o segundo estudo, foi realizado um teste de aleatorização (VAN DER VOET, 1994) com nível de significância de 0,05. O objetivo foi comparar a precisão dos modelos de regressão utilizando diferentes tipos de amostras de cana-de-açúcar no conjunto de validação. As hipóteses avaliadas foram nula ( $H_0$ ) para acurácia (RMSE) similar, e hipótese alternativa ( $H_1$ ) para acurácia não similares.

**RESULTADOS E DISCUSSÃO:** Os dados espectrais de mensurações realizadas em amostras de cana desfibrada no primeiro estudo apresentaram melhor acurácia na validação cruzada (menor RMSE) quando foram pré-processados por meio do método *standard normalize variation* (SNV) (BARNES; DHANOA; LISTER, 1989) seguido pela segunda derivação usando o algoritmo Savitzky-Golay (SAVITZKY; GOLAY, 1964), com janela de nove bandas espectrais e polinômio de grau dois.

Os valores para Brix correspondentes às amostras de calibração possibilitaram representar as amostras obtidas no campo, com range de variação daquelas (valores máximos e mínimos) superior ao destas (Tabela 1). Além disso, os valores de validação externa concentraram-se mais próximo dos valores mínimos observados para o conjunto de calibração.

TABELA 1. Estatística descritiva para as amostras dos conjuntos de calibração e validação externa. **Descriptive statistics of the samples for the calibration and external validation sets.**

	N	Máximo	Média	Mínimo	Mediana	SD	CV
Calibração	350	23,80	20,46	13,80	20,73	1,47	7,22
Validação	90	19,20	17,48	15,70	17,60	0,69	3,99

N – número de amostras; SD – desvio padrão; CV – coeficiente de variação.

Um modelo apropriado deve apresentar baixo valor de RMSE e elevado  $R^2$ , para etapas de calibração e validação externa (NAWI; CHEN; JENSEN, 2013). Os resultados obtidos para os modelos de predição de Brix a partir de amostras de cana desfibrada foram satisfatórios (Figura 3a), apresentando RMSE de 0,66 e 0,80, e  $R^2$  de 0,80 e 0,71 para validação cruzada e validação externa (predição). Usando espectros de absorvância da superfície externa de colmos de cana-de-açúcar, Nawi *et al.* (2013) obtiveram resultados de RMSE de predição de 1,51%, valor maior do que os obtidos no presente estudo.

Os mapas resultantes da interpolação dos resultados obtidos a partir de análises convencionais (Figura 3b) e os mapas resultantes da interpolação dos resultados preditos pelo modelo desenvolvido baseado em NIRS (Figura 3c) mostraram similaridade espacial substancial, baseado em análise visual, resultado do desempenho satisfatório apresentado pelos modelos de predição. Distingue-se uma região com baixo potencial para Brix quando comparada com outras regiões do campo, estendendo-se praticamente por toda a região leste em direção à área central superior. Por outro lado, existe uma região, na área central inferior do talhão, que apresentou um elevado teor de Brix em relação às outras áreas do talhão. Os resultados evidenciam a importância para o mapeamento de atributos de qualidade da cana-de-açúcar, uma vez que existe uma distribuição desigual dos valores Brix ao longo da área. Os modelos geoestatísticos apresentaram valores de

efeito pepita igual a 0,30 e 0,28, alcance de 132,4 e 122,5, e índice de dependência espacial de 62,9 e 52,6% para valores observados e preditos, respectivamente, apresentando dependência espacial moderada (CAMBARDELLA *et al.*, 1994).

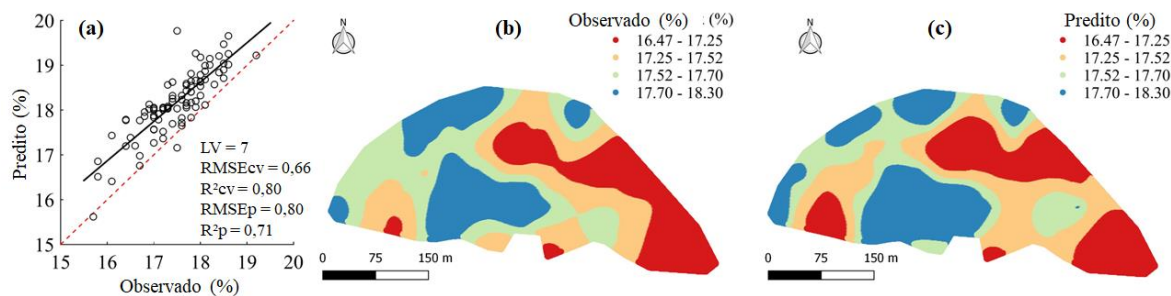


FIGURA 3. Gráfico de dispersão de teores de conteúdo de sólidos solúveis (Brix) do conjunto de dados de validação externa (a). Mapas de Brix observado (b) e predito (c) baseado em regressão por mínimos quadrados parciais a partir de dados de NIRS. **Scatter plot of measured versus predicted solids soluble content (Brix) of external validation data set. Maps of Brix measured (b) and predicted (c) based on partial least squares (PLS) regression from NIRS data.**

A utilização de NIRS proporcionou um método prático, rápido, preciso e confiável para predição de Brix. Acredita-se que a preparação mínima deve resolver a questão da variabilidade do conteúdo ao longo do caule da cana, uma vez que proporciona uma amostragem mais uniforme e homogênea. Embora a colheita da cana-de-açúcar seja um ambiente particularmente desafiador e a ausência de preparação de amostras seja um aspecto desejável para o desenvolvimento de um sensor embarcado. Alguns pesquisadores alcançaram resultados satisfatórios na predição do Brix em condições controladas baseados em mensurações de colmos (PHETPAN; UDOMPETAIKUL; SIRISOMBOON, 2018; UDOMPETAIKUL; PHETPAN; SIRISOMBOON, 2021). No entanto, é necessário avançar para aplicações no campo, principalmente quanto ao método de amostragem e técnicas de processamento dos dados espectrais coletados.

No segundo estudo, os resultados para análise convencional das amostras obtidas ao longo de uma safra, onde buscou-se avaliar diferentes tipos de amostra quanto ao potencial preditivo, permitiram obter grande variação nos teores de Brix (Tabela 2). O algoritmo de Kennard-Stone permitiu a seleção de um conjunto de dados representativo da população de estudo quanto à distribuição de teores mínimos e máximos.

TABELA 2. Estatística descritiva dos resultados de referência de Brix de todas as amostras, conjuntos de calibração e validação externa. **Descriptive statistics of the reference results for Brix of all samples, calibration, and external validation data sets.**

	N	Máximo	Média	Mínimo	Mediana	SD	CV
Todos	302	23,42	18,95	13,08	18,99	1,71	9,02
Calibração	227	23,42	18,86	13,08	18,80	1,66	8,80
Validação externa	75	23,05	19,24	13,55	19,59	1,85	9,62

N – número de amostras; SD – desvio padrão; CV – coeficiente de variação.

Houve uma subestimativa de valores elevados de Brix e uma superestimativa de valores mais baixos para todos os tipos de amostras avaliados (Figura 4). Entretanto, este efeito foi mais intenso para as condições de amostras sem preparo, tais como para dados obtidos por mensuração na casca (SS) e na secção transversal (CSS) dos colmos, quando comparado às amostras preparadas (cana desfibrada – DF, e caldo cru – RJ).




FIGURA 4. Gráficos de valores observados versus preditos de Brix de cana-de-açúcar a partir de espectroscopia vis-NIR com medições na casca (SS) e secção transversal (CSS), cana desfibrada (DF) e caldo cru (RJ). **Plots of observed values versus predicted sugarcane Brix from vis-NIR by skin (SS) and cross-sectional (CSS) scanning of billets, defibrated (DF), and raw juice (RJ) samples.**

Não houve diferença significativa entre a acurácia dos modelos ( $p$ -valor > 0,05) ao avaliar-se comparativamente todas os tipos de amostra, exceto para comparação entre SS e CSS (Tabela 3). Além disso, o desempenho apresentado para predição de Brix a partir de amostras de DF e RJ foi similar, com valores de R<sup>2</sup>p e RPIQ próximos, e menor número de variáveis latentes (conferindo menor complexidade aos modelos), evidenciando que o preparo da cana por moagem e homogeneização é o suficiente para determinação do atributo de qualidade. Amostras sem preparo, como SS e CSS, não apresentaram diferença significativa na acurácia quando comparadas a amostras de DF e RJ (Tabela 3). Entretanto, o desempenho caracterizado pelos valores de R<sup>2</sup> e RPIQ foi inferior (Figura 4).

TABELA 3.  $p$ -Valores obtidos com o teste de aleatorização para o conjunto de dados de validação externa para comparação binária entre os tipos de amostra avaliados.  **$p$ -Values of randomization test of external validation set for all compared sugarcane sample types.**

Comparação binária entre tipos de amostras						
	SS vs. CSS	SS vs. DF	SS vs. RJ	CSS vs. DF	CSS vs. RJ	DF vs. RJ
$p$ -valor	0,104	1,00	1,00	1,00	1,00	0,879

Em estudo precursor, Nawi et al. (2013) obtiveram valores de 0,87 para o R<sup>2</sup>p. O desempenho satisfatório desta métrica pode ser explicado pelo método de aquisição de dados adotado pelos autores, com amostras individualizadas de acordo com a porção do caule (porção inferior, média e superior). O acúmulo de sacarose ocorre de forma ascendente, com mais concentração de açúcares na porção inferior e menos nos entrenós da porção superior, perto das folhas (WANG, et al., 2017). Contudo, se analisarmos as características de uma colhedora de cana-de-açúcar, após os caules passarem pelo sistema de rolos picadores, a distinção entre as porções do caule não é viável. Por outro lado, o preparo de amostras desfibradas constitui-se um método destrutivo e que pode ser impraticável para uma adaptação visando obter mensurações em tempo real. Assim, é necessário avançar em estudos aplicando técnicas de processamento de dados multivariados, como transferência de calibração, a fim de possibilitar a obtenção de dados de qualidade sem preparo de amostras.

No terceiro estudo, o algoritmo de Kennard-Stone para segmentação de dados permitiu obter um conjunto de calibração cujo intervalo de valores máximo e mínimo foi representativo do conjunto de dados completo (Tabela 4). Este efeito é desejável para que o conjunto de dados de calibração caracterize a variação existente em todo o conjunto de dados que caracteriza a população (talhões) de estudo.

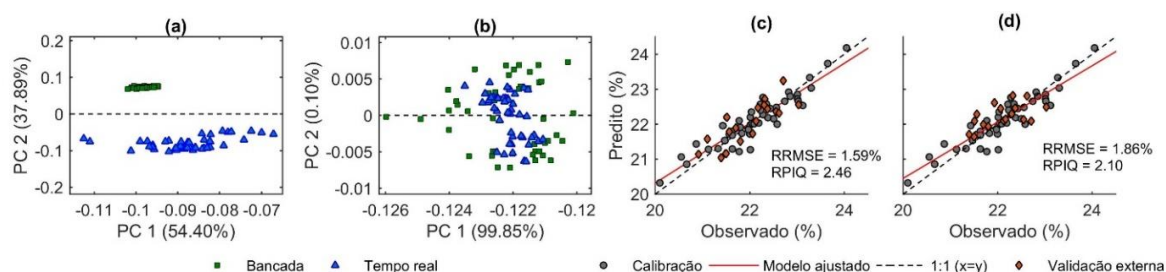
TABELA 4. Estatística descritiva dos resultados de referência de Brix de todas as amostras, conjuntos de calibração e validação externa. **Descriptive statistics of the sugarcane quality parameters for all collected samples, for the cross-validation and prediction data set.**

	N	Máximo	Média	Mínimo	Mediana	SD	CV
Todos	66	24,05	22,09	20,10	22,09	0,73	3,30

Calibração	47	24,05	22,14	20,10	22,11	0,79	3,57
Validação	19	23,03	21,98	20,92	21,94	0,57	2,59

N – número de amostras; SD – desvio padrão; CV – coeficiente de variação.

Por meio de uma análise exploratória de componentes principais (PCA) é possível observar o efeito do método PDS de transferência de calibração sobre os espectros obtidos pelo sensor embarcado (Figura 5). Antes de aplicar o PDS, espectros de amostras de cana desfibrada obtidos em condições controladas apresentaram diferenças evidentes quanto à variância dos dados explicada pela PCA (Figura 5a). A variância dos dados obtidos nas medições em tempo real possivelmente ocorreu devido a fatores ambientais adversos intrínsecos da colheita mecanizada sob medições espectrais quando comparadas às medições em condições controladas. Por outro lado, após a aplicação do modelo PDS nas medições em tempo real, os escores são exibidos no espaço do conjunto mestre, ou seja, os espectros de cana desfibrada (Figura 5b). Além disso, os dois primeiros componentes explicaram 90,73% da variância dos dados antes da transferência de calibração, e após a transferência de calibração, 99,85% da variância de ambos os conjuntos de dados passou a ser explicada apenas pela primeira componente principal. Este resultado indica que a variância devida à diferença entre os dados espectrais correspondentes às amostras de cana desfibrada medidas sob condições controladas e as amostras obtidas com as medições a bordo foi substancialmente reduzida.



Gráfico, Gráfico de dispersão Descrição gerada automaticamente

FIGURA 5. Os escores dos componentes principais para predição por sensor embarcado (em tempo real), e amostras de cana desfibradas medidas em laboratório (bancada), antes (a) e depois (b) da transferência de calibração por PDS (*Piecewise Direct Standardization*), e porcentagem de variação explicada por cada componente mostrada nos eixos entre parênteses. Valores preditos versus valores observados a partir de cana desfibrada (c) e a partir de modelos PLS-PDS para mensuração em tempo real (d). **The principal component scores for on-board field prediction (real time), and defibrated cane samples measured in the laboratory (benchtop), before (a) and after (b) calibration transfer by Piecewise Direct Standardization (PDS), and the percentage of variance explained by each component is shown on the axes in parentheses. Predicted vs. measured values from defibrated cane (c) and from PLS-PDS models from on-board measurements (d).**

Houve substancial similaridade entre a performance de ambos os modelos de predição, utilizando condições controladas, a partir da mensuração de amostras de cana desfibrada em bancada (Figura 5c) e com mensurações em tempo real e utilizando o método PDS para transferência de calibração (Figura 5d), com valores de RPIQ iguais a 2,46 e 2,10 respectivamente. Além disso, a acurácia relativa de ambos os modelos apresentou valores próximos, com RRMSE iguais a 1,86% e 1,59%, para mensurações na colhedora e em bancada, respectivamente. Em estudo precursor, Nawi et al. (2013) alcançaram RRMSEP igual 8,47% e 7,91% para a predição de Brix por meio de espectros de absorvância NIR e de reflectância, respectivamente, para medições realizadas na superfície exterior da casca em condições controladas. Em outro estudo, baseado em medições da secção transversal de amostras de colmos em condições controladas, Nawi, Chen e Jensen (2013) atingiram valores RRMSEP de até 8,13% para a predição de Brix. Os resultados apresentados foram inferiores aos obtidos no presente estudo, embora realizados em condições controladas, evidenciando que o método de transferência de calibração pode ser eficaz para realizar o pós-processamento de dados espectrais coletados em tempo real com sensor embarcado em colhedoras de cana-de-açúcar.

Os teores de Brix apresentaram dependência espacial moderada (CAMBARDELLA *et al.*, 1994) para as três áreas de estudo (Tabela 5). No primeiro estudo, também foi observada dependência espacial moderada a partir do mapa gerado por interpolação de amostras coletadas em campo e analisadas em laboratório. Rodrigues,


Magalhães e Franco (2013) observaram dependência espacial fraca a moderada para Brix predito a partir de modelos matemáticos ajustados a partir de parâmetros físico-químicos do solo e nitrogênio foliar como variáveis preditoras.

TABELA 5. Parâmetros do semivariograma dos modelos ajustados para análise da variabilidade espacial de Brix das três áreas avaliadas. **Semivariogram parameters of the models fitted to analyze the spatial variability of Brix in the three fields evaluated.**

Área	Modelo	C0	C0 + C1	A (m)	C0 / (C0 + C1)
A	Exponencial	0,060	0,098	33,62	0,61
B	Exponencial	0,252	0,363	64,48	0,69
C	Exponencial	0,381	0,517	38,76	0,74

C0 – efeito pepita; C1 – semivariância estrutural; A – alcance

Os mapas de qualidade da cana-de-açúcar, obtidos a partir do modelo de predição PLS-PDS gerado, mostraram efeitos evidentes da variabilidade nos campos experimentais (Figura 6). Além disso, a variabilidade entre as diferentes áreas é ainda mais evidente. O campo C apresentou uma maior área com baixas concentrações de Brix do que os campos A e B. A modelagem permitiu discriminar valores altos e baixos de Brix, mesmo em áreas pequenas, e especialmente em distâncias maiores. Foi possível observar variações relativas de 7,14% entre valores máximos e mínimos para os campos experimentais. Para avançar na aplicação da técnica de mensuração de qualidade em tempo real torna-se essencial a avaliação em áreas extensas, em diferentes momentos ao longo de uma mesma safra, e entre diferentes safras. A aquisição de uma tal base de dados permitirá o desenvolvimento de modelos de calibração mais robustos, inserindo maior variabilidade dos teores no desenvolvimento dos modelos de predição, e permitindo a avaliação de técnicas mais robustas para processamento de dados como métodos não-lineares (SEXTON *et al.*, 2020). Além disso, recomenda-se a avaliação de outras técnicas de transferência de calibração e ortogonalização de dados multivariados. Por fim, é importante a avaliação da interferência da temperatura do ambiente ao longo do dia, uma vez que esse parâmetro pode contribuir com vibrações moleculares dos compostos orgânicos (PASQUINI, 2018) afetando a qualidade do sinal mensurado. A utilização deste atributo combinado com dados de produtividade, pode permitir a aquisição de mapas de variabilidade da quantidade de açúcares produzidos por área. Constitui uma informação valiosa para a gestão agrônômica dos insumos agrícolas, visando a qualidade do produto fornecido às usinas e para a gestão financeira de toda a operação.



Tela de computador com texto preto sobre fundo branco Descrição gerada automaticamente com confiança média

FIGURA 6. Mapas de variabilidade espacial de Brix da cana-de-açúcar para os três campos experimentais medidos a partir de sensor NIR embarcado na colhedora e preditos pelo modelo de regressão PLS combinado com o método de transferência de calibração *piecewise direct standardization*. **Sugarcane Brix spatial variability maps for the three experimental fields measured by on-board NIR sensor on the harvester and predicted by PLS regression model combined with piecewise direct standardization calibration transfer method.**

**CONCLUSÃO:** (i) O teor de sólidos solúveis da cana-de-açúcar apresentou dependência espacial moderada, quando estimado por meio de amostragem e mensuração por NIRS em cana desfibrada; (ii) Não houve diferença estatística significativa na acurácia (RMSE) de mensuração de Brix para amostras sem preparo, como



colmo inteiro, quando comparado a amostras desfibradas e de caldo, entretanto, o potencial preditivo (RPIQ e R<sup>2</sup>) de amostras desfibradas foi superior ao das demais formas; e (iii) O método de transferência de calibração *piecewise direct standardization* permitiu realizar o pós-processamento de mensurações espectrais realizadas em tempo real com sensor embarcado, baseado em mensurações realizadas em condições controladas com amostras de cana desfibrada, identifica a dependência espacial moderada do Brix, e assim mapear a variabilidade espacial do atributo de qualidade em áreas de uma lavoura comercial.

#### AGRADECIMENTOS:

O estudo foi financiado por meio do processo nº 2018/25008-8, Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), referente ao doutoramento do primeiro autor. Agradecemos ao grupo São Martinho e à Spectral Solutions por prover a infraestrutura e equipamentos para a aquisição de dados do experimento.

#### REFERÊNCIAS

BARNES, R. J.; DHANOA, M. S.; LISTER, S. J. Standard normal variate transformation and de-trending of near-infrared diffuse reflectance spectra. **Applied Spectroscopy**, vol. 43, no. 5, p. 772–777, 1989. <https://doi.org/10.1366/0003702894202201>.

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**, vol. 58, no. 5, p. 1501–1511, 1994. <https://doi.org/10.2136/sssaj1994.03615995005800050033x>.

COLAÇO, A. F.; MOLIN, J. P.; ROSELL-POLO, J. R.; ESCOLÀ, A. Spatial variability in commercial orange groves. Part 2: relating canopy geometry to soil attributes and historical yield. **Precision Agriculture**, vol. 20, no. 4, p. 805–822, 2019. DOI 10.1007/s11119-018-9615-0. Available at: <https://doi.org/10.1007/s11119-018-9615-0>.

CONSECANA. National Concill of Sugarcane Producers of Sa?o Paulo State. vol. 6, p. 81, 2015. .

CORTÉS, V.; BLASCO, J.; ALEIXOS, N.; CUBERO, S.; TALENS, P. Monitoring strategies for quality control of agricultural products using visible and near-infrared spectroscopy: A review. **Trends in Food Science and Technology**, vol. 85, p. 138–148, 1 Mar. 2019. <https://doi.org/10.1016/j.tifs.2019.01.015>.

FERRAZ, M. N.; CORRÊDO, L. P.; WEI, M. C. F.; MOLIN, J. P. Spatial variability mapping of sugarcane qualitative attributes. **Engenharia Agrícola**, vol. 39, no. spe, p. 109–117, 2019. DOI 10.1590/1809-4430-eng.agric.v39nep109-117/2019. Available at: <http://dx.doi.org/10.1590/1809-4430-Eng.Agric.v39nep109-117/2019>.

JI, W.; VISCARRA ROSSEL, R. A.; SHI, Z. Improved estimates of organic carbon using proximally sensed vis-NIR spectra corrected by piecewise direct standardization. **European Journal of Soil Science**, vol. 66, no. 4, p. 670–678, 1 Jul. 2015. DOI 10.1111/ejss.12271. Available at: <https://onlinelibrary.wiley.com/doi/full/10.1111/ejss.12271>.

KENNARD, R. W.; STONE, L. A. Computer Aided Design of Experiments. **Technometrics**, vol. 11, no. 1, p. 137–148, 1969. <https://doi.org/10.1080/00401706.1969.10490666>.

MARAPHUM, K.; CHUAN-UDOM, S.; SAENGPRACHATANARUG, K.; WONGPICHET, S.; POSOM, J.; PHUPHAPHUD, A.; TAIRA, E. Effect of waxy material and measurement position of a sugarcane stalk on the rapid determination of Pol value using a portable near infrared instrument. **Journal of Near Infrared Spectroscopy**, vol. 26, no. 5, p. 287–296, 2018. DOI 10.1177/0967033518795810. Available at: <https://journals.sagepub.com/doi/pdf/10.1177/0967033518795810>.

- MAYRINK, G. O.; VALENTE, D. S. M.; QUEIROZ, D. M.; PINTO, F. A. C.; TEOFILO, R. F. Determination of chemical soil properties using diffuse reflectance and ion-exchange resins. **Precision Agriculture**, vol. 20, p. 541–561, 2019. DOI 10.1007/s11119-018-9597-y. Available at: <https://doi.org/10.1007/s11119-018-9597-y>.
- NAWAR, S.; MUNNAF, M. A.; MOUAZEN, A. M. Machine learning based on-line prediction of soil organic carbon after removal of soil moisture effect. **Remote Sensing**, vol. 12, no. 8, p. 1308, 1 Apr. 2020. DOI 10.3390/RS12081308. Available at: [www.mdpi.com/journal/remotesensing](http://www.mdpi.com/journal/remotesensing).
- NAWI, N. M.; CHEN, G.; JENSEN, T. In-field measurement and sampling technologies for monitoring quality in the sugarcane industry: a review. **Precision Agriculture**, vol. 15, no. 6, p. 684–703, 2014. <https://doi.org/10.1007/s11119-014-9362-9>.
- NAWI, N. M.; CHEN, G.; JENSEN, T. Visible and shortwave near infrared spectroscopy for predicting sugar content of sugarcane based on a cross-sectional scanning method. **Journal of Near Infrared Spectroscopy**, vol. 21, no. 4, p. 289–297, 2013. <https://doi.org/10.1255/jnirs.1060>.
- NAWI, N. M.; CHEN, G.; JENSEN, T.; MEHDIZADEH, S. A. Prediction and classification of sugar content of sugarcane based on skin scanning using visible and shortwave near infrared. **Biosystems Engineering**, vol. 115, p. 154–161, 2013. DOI 10.1016/j.biosystemseng.2013.03.005. Available at: <http://dx.doi.org/10.1016/j.biosystemseng.2013.03.005>.
- PAGANI, V.; STELLA, T.; GUARNERI, T.; FINOTTO, G.; VAN DEN BERG, M.; MARIN, F. R.; ACUTIS, M.; CONFALONIERI, R. Forecasting sugarcane yields using agro-climatic indicators and Canegro model: A case study in the main production region in Brazil. **Agricultural Systems**, vol. 154, p. 45–52, 1 Jun. 2017. <https://doi.org/10.1016/j.agsy.2017.03.002>.
- PASQUINI, C. Near infrared spectroscopy: A mature analytical technique with new perspectives – A review. **Analytica Chimica Acta**, vol. 1026, p. 8–36, Oct. 2018. DOI 10.1016/j.aca.2018.04.004. Available at: <https://linkinghub.elsevier.com/retrieve/pii/S0003267018304793>.
- PHETPAN, K.; UDOMPETAIKUL, V.; SIRISOMBOON, P. An online visible and near-infrared spectroscopic technique for the real-time evaluation of the soluble solids content of sugarcane billets on an elevator conveyor. **Computers and Electronics in Agriculture**, vol. 154, p. 460–466, Nov. 2018. DOI 10.1016/j.compag.2018.09.033. Available at: <https://linkinghub.elsevier.com/retrieve/pii/S0168169918302096>.
- PHUPHAPHUD, A.; SAENGPRACHATANARUG, K.; POSOM, J.; MARAPHUM, K.; TAIRA, E. Non-destructive and rapid measurement of sugar content in growing cane stalks for breeding programmes using visible-near infrared spectroscopy. **Biosystems Engineering**, vol. 197, p. 76–90, 1 Sep. 2020. <https://doi.org/10.1016/j.biosystemseng.2020.06.012>.
- PHUPHAPHUD, A.; SAENGPRACHATANARUG, K.; POSOM, J.; MARAPHUM, K.; TAIRA, E. Prediction of the fibre content of sugarcane stalk by direct scanning using visible-shortwave near infrared spectroscopy. **Vibrational Spectroscopy**, vol. 101, p. 71–80, Mar. 2019. DOI 10.1016/j.vibspec.2019.02.005. Available at: <https://linkinghub.elsevier.com/retrieve/pii/S0924203118302613>.
- POREP, J. U.; KAMMERER, D. R.; CARLE, R. On-line application of near infrared (NIR) spectroscopy in food production. **Trends in Food Science and Technology**, vol. 46, no. 2, p. 211–230, 1 Dec. 2015. <https://doi.org/10.1016/j.tifs.2015.10.002>.
- RODRIGUES, F. A.; MAGALHÃES, P. S. G.; FRANCO, H. C. J. Soil attributes and leaf nitrogen estimating sugar cane quality parameters: Brix, pol and fibre. **Precision Agriculture**, 2013. <https://doi.org/10.1007/s11119-012-9294-1>.

SAVITZKY, A.; GOLAY, M. J. E. Smoothing and Differentiation of Data by Simplified Least Squares Procedures. **Analytical Chemistry**, vol. 36, no. 8, p. 1627–1639, 1964. DOI 10.1021/ac60214a047. Available at: <https://pubs.acs.org/sharingguidelines>.

SEXTON, J.; EVERINGHAM, Y.; DONALD, D.; STAUNTON, S.; WHITE, R. Investigating the identification of atypical sugarcane using NIR analysis of online mill data. **Computers and Electronics in Agriculture**, vol. 168, 1 Jan. 2020. DOI 10.1016/j.compag.2019.105111. Available at: <https://doi.org/10.1016/j.compag.2019.105111>.

UDOMPETAIKUL, V.; PHETPAN, K.; SIRISOMBOON, P. Development of the partial least-squares model to determine the soluble solids content of sugarcane billets on an elevator conveyor. **Measurement**, vol. 167, p. 107898, 1 Jan. 2021. DOI 10.1016/j.measurement.2020.107898. Available at: <https://linkinghub.elsevier.com/retrieve/pii/S026322412030436X>.

VAN DER VOET, H. Comparing the predictive accuracy of models using a simple randomization test. **Chemometrics and Intelligent Laboratory Systems**, vol. 25, no. 2, p. 313–323, 1994. [https://doi.org/10.1016/0169-7439\(94\)85050-X](https://doi.org/10.1016/0169-7439(94)85050-X).

WALSH, K. B.; BLASCO, J.; ZUDE-SASSE, M.; SUN, X. Visible-NIR ‘point’ spectroscopy in postharvest fruit and vegetable assessment: The science behind three decades of commercial use. **Postharvest Biology and Technology**, vol. 168, p. 111246, 1 Oct. 2020. <https://doi.org/10.1016/j.postharvbio.2020.111246>.

WANG, J.; ZHAO, T.; YANG, B.; ZHANG, S. Sucrose Metabolism and Regulation in Sugarcane. **Journal of Plant Physiology & Pathology**, vol. 05, no. 04, 7 Feb. 2017. <https://doi.org/10.4172/2329-955x.1000167>.

WANG, Y.; VELTKAMP, D. J.; KOWALSKI, B. R. Multivariate Instrument Standardization. **Analytical Chemistry**, vol. 63, no. 23, p. 2750–2756, 1 Dec. 1991. DOI 10.1021/ac00023a016. Available at: <https://pubs.acs.org/doi/abs/10.1021/ac00023a016>.



# DESENVOLVIMENTO DE UM SENSOR ÓPTICO PARA MENSURAÇÃO DE ATRIBUTOS FÍSICOS DE TOMATES A PARTIR DE IMAGENS DIGITAIS

João Célio Luna de Carvalho<sup>1</sup>; Anderson Gomide Costa<sup>2</sup>

<sup>1</sup>Eng Agrícola e Ambiental, Graduando - Depto. Engenharia, UFRRJ, Seropédica-RJ. joacelio1301@gmail.com / (21) 9 6418-6077; <sup>2</sup>Eng Agrícola e Ambiental, Doutor Professor - Depto. Engenharia, UFRRJ, Seropédica-RJ

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** No contexto da Agricultura 4.0, o uso de sistemas de visão artificial de máquinas possibilitam a automação do controle de qualidade de alimentos por meio do reconhecimento de padrões de tamanho, forma, cor e textura a partir de imagens digitais. Sistemas ópticos têm sido aplicados como alternativa não destrutiva e de baixo custo para mensurar parâmetros de qualidade de frutos. Diante desta perspectiva, este trabalho teve como objetivo desenvolver um algoritmo capaz de mensurar parâmetros físicos de frutos de tomate a partir de imagens digitais que será aplicado em um dispositivo que poderá avaliar a variabilidade espacial destes atributos em campo. O algoritmo foi desenvolvido em linguagem Python, possibilitando que a partir de duas imagens de um mesmo fruto de tomate seja possível calcular o volume, diâmetro, esfericidade e área da superfície. O algoritmo foi testado em uma imagem simulada de formato circunferencial, em uma imagem de objeto real na forma elipsoidal e em uma imagem de um tomate do tipo Saladete. O algoritmo se mostrou apto a calcular as propriedades físicas e estimar os volumes das imagens analisadas, mostrando-se pronto para realização de testes de validação e posterior implementação em um dispositivo óptico portátil e com um sistema de georeferência, baseado no microprocessador Raspberry PI, que seja capaz coletar os dados de forma permitir a geração de mapas de variabilidade espacial destes atributos em campo.

**PALAVRAS-CHAVE:** Qualidade dos tomates; Métodos não-destrutivos; Variabilidade espacial

## DEVELOPMENT OF AN OPTICAL SENSOR FOR MEASURING PHYSICAL ATTRIBUTES OF TOMATOES FROM DIGITAL IMAGES

**ABSTRACT:** In the context of Agriculture 4.0, the use of machine vision systems makes it possible to automate food quality control through the recognition of patterns in size, shape, color and texture from digital images. Optical systems have been applied as a non-destructive and low-cost alternative to measure fruit quality parameters. Given this perspective, this work aimed to develop an algorithm capable of measuring physical parameters of tomato fruits from digital images that will be applied in a device that will be able to evaluate the spatial variability of these attributes in the field. The algorithm was developed in Python language, allowing that from two images of the same tomato fruit it is possible to calculate the volume, diameter, sphericity and surface area. of real object in ellipsoidal shape and in an image of a Saladette type tomato. The algorithm proved to be able to calculate the physical properties and estimate the volumes of the analyzed images, showing itself ready to carry out the validation test stage and subsequent implementation in a portable optical device and with a georeference system, based on the Raspberry PI microprocessor. , which is able to collect data in a way that allows the generation of maps of spatial variability of these attributes in the field.

**KEYWORDS:** Tomato Quality; Non-destructive methods; Spatial variability

**INTRODUÇÃO:** Sistemas de visão artificial são eficientes na extração e quantificação não destrutiva das características de qualidade e controle de frutos (Rodrigues et al., 2013).

Tecnologias de seleção automatizada e qualidade de tomates são de preocupação generalizada, alvo de pesquisas internacionais visando o reconhecimento do fruto na planta, determinação do grau de maturação e estimativas de suas propriedades físicas (Zaborowicz et al., 2017). O conhecimento de propriedades como peso, volume, diâmetros dos frutos e área superficial são parâmetros necessários para o desenvolvimento de projetos de a automatização da colheita e pós-colheita dos frutos (COSTA et al., 2016; GOEL et al., 2020).

Um sistema automatizado para seleção de frutos de tomates tem potencial para aplicação em toda produção, e o Brasil apresenta baixo uso da tecnologia. Inspeções humanas comumente utilizam a base de padronizações de referências do Centro de Qualidade em Horticultura (CEAGESP, 2003), com base em cor e aspectos físicos.

Estes dispositivos se associados a sistemas de georreferenciamento, possibilita que os atributos sejam coletados com perspectiva de variabilidade espacial, possibilitando o manejo localizado. Apesar dos altos custos iniciais de implantação deste sistema, verifica-se que há tendência de evolução da tecnologia no campo, com redução gradual dos custos, garantindo a viabilidade técnica e econômica (SILVA et al., 2011). Medeiros et al. (2016), desenvolveu tecnologias de sensoriamento remoto proximal de aquisição de informações espaciais dos campos de produção, reduzindo tempo e custos na geração de mapas de atributos de solos.

Assim, o objetivo deste trabalho foi desenvolver um algoritmo na linguagem Python que mensura, por imagens digitais, atributos físicos volume, diâmetro, esfericidade e área da superfície dos frutos de tomate, classificando-os por formato. também poderá ser implementado um sensor óptico portátil, de baixo custo, utilizando o microprocessador Raspberry Pi, mensurando características de forma instantânea e não destrutiva, coletando dados de forma a permitir a geração de mapas de variabilidade espacial.

## **MATERIAIS E MÉTODOS:**

O algoritmo desenvolvido teve como objetivo obter atributos físicos do tomate (Diâmetro geométrico, Diâmetro Aritmético, Esfericidade e a área de superfície do fruto) a partir de quatro imagens do fruto. Uma vez implementado no dispositivo óptico, esses atributos poderão ser obtidos diretamente na lavoura e georreferenciados pelo módulo GNSS, o que possibilitará a geração de mapas de variabilidade espacial. O algoritmo foi desenvolvido em linguagem Python, utilizando os módulos OpenCV2, Math e Numpy na codificação do programa. O programa foi dividido em funções que executam outras funções, para realizar os objetivos previstos no trabalho. Primeiramente foi desenvolvida uma função, denominada “ObterValores”, a qual solicita, inicialmente, uma largura para redimensionar a imagem. O objetivo desta etapa foi acelerar o processamento, obtendo os melhores resultados. A partir dos testes realizados, sugere-se utilizar a largura de 500 pixels para as imagens. São armazenados as alturas, diâmetros e distâncias ponto a ponto do fruto, que serão processados posteriormente. Após a solicitação da largura, o algoritmo realiza a função nomeada como “ObterProporcao”. Esta função visa obter o valor de altura da imagem, para seu posterior redimensionamento. Retorna-se, em forma de tupla (lista de dados inalterável), a nova largura e altura. O objetivo dessa função é evitar a distorção da imagem. Com os valores obtidos, a próxima função executada é a “Redimensionador”, do qual carrega a imagem original e a tupla com os valores de altura e largura, redimensiona a imagem e salva-a temporariamente na unidade de armazenamento. A função executada em sequência é a “AlturaELargura”, aplicada na imagem redimensionada. Esta função se baseia no processamento “BordasCanny” e “Binarizador” que retorna a imagem binarizada, com limites de threshold de 150 a 255 e retornando a imagem com as bordas demarcadas. Essas funções são nativas do OpenCV2. A função “ObterValores” também cria 4 pontos de referências (X,Y), todos inicialmente zerados, junto do ponto de início e de fim de cada linha do fruto, horizontalmente. Assim, para cada linha X, é lido cada pixel Y. Se o valor for 0 (preto), a função avança para o próximo pixel. Se o pixel for diferente de 0 (branco), é adicionado à memória uma tupla com os dados da coordenada do ponto detectado, alterando também o valor armazenado de início da linha, anteriormente 0. A partir daí, os valores são armazenados na constante de fim da linha, exceto se forem de valor 0 (preto), até o término do processo de varredura. Com o fim da varredura, é subtraído do final da linha o valor do seu início, obtendo-se a largura. O cálculo da altura é feito baseado no resultado dessa operação, no qual somente será adicionado um pixel a altura caso o resultado seja diferente de 0. A função também armazena as diferenças na lista de distancias. O processo é reiniciado, com as coordenadas de referência de início e fim da linha, junto do valor de Y zerados, e X recebe mais uma unidade, partindo para a linha inferior da imagem. O processo se repete até que a varredura esteja completa.

Ao Final, a função AlturaELargura retorna os valores de altura, diâmetro do fruto e a lista com as distancias das camadas em pixels. Com estes valores, é solicitada a função “RetornarValorOriginal”, da qual calcula a proporção entre a imagem original e a redimensionada, retornando a razão original/redimensionada e deletando a imagem redimensionada da memória. Assim, ao final da “ObterValores”, os valores de Diâmetro e Altura são redimensionados conforme a razão de proporção obtida anteriormente, e as distâncias são armazenadas em listas na memória. É retornado a média das quatro alturas e dos diâmetros opostos, junto da lista de distâncias

e o valor de proporção real. Com os valores obtidos anteriormente pela função “ObterValores”, o algoritmo calcula os valores de diâmetro médio geométrico ( $D_g$ ), Diâmetro médio aritmético ( $D_a$ ), Esfericidade ( $E_s$ ) e Área da superfície ( $A_s$ ) dos frutos de tomate de acordo com Liu, et al. (2015), sendo retornados numa única lista. A partir das 4 imagens dos frutos de tomates, foi obtido os diâmetros como sendo uma média do par da imagem e a sua correspondente oposta. Baseada na lista de distâncias retornada em “ObterValores”, a função “Diametros” calcula os diâmetros em cada camada da imagem, realizando a média dos 2 valores, caso existam, e utilizando somente o único existente. A implementação dessa condição é importante pois um pequeno defeito de iluminação, deformação ou posicionamento do fruto poderá ser compensado, reduzindo o erro no resultado final. São retornados assim, duas listas, cada uma de diâmetros laterais e outra dos frontais.

A partir dos valores de diâmetros determinados, foi possível estimar o volume do fruto. Assim, a função “Volume”, utilizando das 2 listas, calcula a área da camada numa linha junto da camada abaixo, considerando cada camada uma elipse, e é feito a média desses dois valores. Ao ser multiplicado pelo valor de 1 pixel, é convertendo em volume. O processo foi repetido até a penúltima camada, somando os valores obtidos constantemente, seguindo o princípio da integral. Com o volume calculado em pixels, é necessário converter para o volume da imagem real. Assim, utilizando-se do valor de proporção real, retornado pela função “ObterValores”, obtém-se o real volume do fruto.

O tipo do tomate em função do formato foi classificado pela razão entre os diâmetros e altura, conforme a Tabela 1. A função “ObterFormato” calcula o valor e retorna o tipo do fruto, sendo ele Caqui, Saladete, Santa Cruz ou Italiano, segundo a CEAGESP, (2003).

TABELA 1. Classificação do tomate (CEAGESP, 2003).

Classificação	Razão
Caqui	Menor que 0,90
Saladete	Entre 0,90 e 1,00
Santa Cruz	Entre 1,00 e 1,15
Italiano	Maior que 1,15

Para a validação do algoritmo, foram utilizadas três imagens de diferentes perfis a fim de caracterizar as propriedades físicas Diâmetro médio geométrico, Diâmetro médio aritmético, Esfericidade, Área da superfície e Volume dos frutos. Foram utilizados os seguintes perfis de imagens: imagem simulada de formato circunferencial, imagem de objeto real na forma elipsoidal e em uma imagem de um tomate do tipo Saladete.

### Construção do dispositivo óptico

A construção do dispositivo óptico ainda esta em desenvolvimento e se dará em uma estrutura cúbica, possuindo um módulo de câmera (FIGURA 2) conectado a um microcomputador Raspberry Pi 3 (FIGURA 1). Em anexo ao sistema, será implementado um módulo GPS NEO-6M (FIGURA 3). Vale ressaltar que se encontra em andamento a implementação deste módulo, objetivando a aplicação de um sistema de variabilidade espacial e georreferenciamento. Assim, cada valor de atributo obtido será georreferenciado, possibilitando a criação de um mapa de variabilidade das características físicas dos frutos.



FIGURA 1. Microprocessador Raspberry Pi 3. **Raspberry Pi 3 microprocessor.**




FIGURA 2. Módulo de Câmera para Raspberry Pi. **Camera Module for Raspberry Pi.**



FIGURA 3. Módulo GPS NEO-6M. **NEO-6M GPS module.**

**RESULTADOS E DISCUSSÃO:** O algoritmo desenvolvido foi capaz de executar etapas que permite mensurar o Diâmetro médio geométrico, Diâmetro médio aritmético, Esfericidade, Área da superfície e Volume dos frutos de tomate. Para o teste de funcionamento, o algoritmo foi aplicado em três imagens com diferentes perfis: imagem simulada de formato circunferencial, imagem de objeto real na forma elipsoidal e em uma imagem de um tomate do tipo Saladete. Para o teste com o círculo, o algoritmo se mostrou eficiente na estimativa das propriedades físicas, apresentando resultados compatíveis, com a esfericidade bem próxima de 1. Acredita-se que o resultado não foi perfeito devido a pequena diferença entre os valores de diâmetro e altura. Utilizando-se a batata, observa-se que o algoritmo calcula corretamente os diâmetros e alturas, já que a imagem foi manipulada para obter valores nitidamente diferentes. O teste com o tomate foi realizado para fins de experimentação do programa. Os resultados podem ser vistos na Tabela 2. Os resultados são expressos em pixels.

TABELA 2. Resultados do processamento do programa.

	Imagem Circunferência	Imagem Elipsoidal	Tomate
Classificação	Santa cruz	Snata Cruz	Saladete

Altura (px)	343,20	410,25	731,08
Diâmetro 1 (px)	342,40	294,23	755,18
Diâmetro 2 (px)	343,40	515,51	755,18
Diâmetro geométrico médio (px)	342,67	393,29	747,10
Diâmetro aritmético médio (px)	342,66	406,68	747,15
Área de superfície (px <sup>2</sup> )	368886,75	493362,91	1753313,26
Esfericidade	0,99	0,96	1,022
Volume (px <sup>3</sup> )	21131617,27	0,96	224207893,56

O algoritmo se mostrou apto a calcular as propriedades físicas das imagens analisadas, mostrando-se pronto para realização da etapa de testes de validação e posterior implementação em um dispositivo óptico portátil, baseado no microprocessador Raspberry PI.

Para a conversão da unidade, de pixels centímetros, se faz necessário testes controlados, no qual a distância da câmera deve ser fixa, havendo, junto dela, uma imagem de referência com as medidas. Assim, ao se obter a relação de centímetros por pixel, basta implementar no programa a condição de conversão das medidas. Essa relação deve, preferencialmente, ser aplicada antes da utilização dos valores em fórmulas, evitando eventuais erros.

A construção do protótipo do dispositivo óptico encontra-se em andamento. Uma vez em funcionamento o dispositivo será capaz de mensurar os atributos físicos do tomate e georreferenciar em campo, possibilitando a geração de mapas de variabilidade espacial. Desta forma, o objetivo do georreferenciamento é utilizar-se do poder da agricultura de precisão para auxiliar tanto na tomada de decisão dos produtores quanto em estudos sobre as características dos frutos.

**CONCLUSÃO:** O algoritmo desenvolvido se mostrou apto a calcular as propriedades físicas e estimar os volumes das imagens analisadas, mostrando-se pronto para realização da etapa de testes de validação e posterior implementação em um dispositivo óptico portátil, baseado no microprocessador Raspberry PI. Além da coleta automatizada dos atributos físicos dos tomates, o próximo passo deste trabalho é a utilização do módulo GNSS, visando possibilitar a geração de mapas de variabilidade espacial de diversos atributos físicos dos frutos do tomate, auxiliando no gerenciamento localizado da lavoura.

#### **AGRADECIMENTOS:**

Agradecimentos à Fundação de Amparo à Pesquisa do Estado do Rio de Janeiro – FAPERJ pelo financiamento dos recursos para o custeio deste projeto e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq pelo financiamento da bolsa de iniciação científica.

#### **REFERÊNCIAS**

BANTAYEHU, M.; ALEMAYEHU, M. Efficacy of Postharvest Technologies on Ripening Behavior and Quality of Banana Varieties Grown in Ethiopia. **International Journal of Fruit Science**, p. 1-17, 2019.

CEAGESP - Companhia de Entrepósitos e Armazéns Gerais de São Paulo. Normas para classificação de tomates. São Paulo: CEAGESP, 2003. 2p. **Documento**, 26.

COSTA, A. G.; RIBEIRO, E.; BRAGA, R. A.; PINTO, F. A. Measurement of volume of macaw palm fruit using traditional and the digital Moiré techniques. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 20, n. 2, p. 152-157, 2016.

GOEL, L.; RAMAN, S.; DORA, S. S.; BHUTANI, A.; ADITYA, A. S.; MEHTA, A. Hybrid computational intelligence algorithms and their applications to detect food quality. **Artificial Intelligence Review**, v.53, n..2, 1415-1440p., 2020.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. ESTATÍSTICA MENSAL DA PRODUÇÃO AGRÍCOLA. Levantamento Sistemático da Produção agrícola. **Documento**. Fevereiro, 2018.

LIU, C.; LIU, W.; CHEN, W.; YANG, J.; ZHENG, L. Feasibility in multispectral imaging for predicting the content of bioactive compounds in intact tomato fruit. **Food chemistry**, v.173, 482-488p., 2015.

MEDEIROS, W. N.; QUEIROZ, D. M., VALENTE, D. S. M., PINTO, F. A. C.; MELO, C. A. D. The temporal stability of the variability in apparent soil electrical conductivity. **Bioscience Journal**, v. 32, n. 1, 2016.

RODRIGUES, J. C.; LAVOIER FILHO, J. M.; JORGE, L. A. C. Análise de qualidade de frutas por imagens multiespectrais. **Revista Científica Eletrônica UNISEB**, v. 1, n. 1, p. 91-110, 2013.

SILVA, C. B.; MORETTO, A. C.; RODRIGUES, R. L. Viabilidade econômica da agricultura de precisão: o caso do Paraná. **In: Congresso da Sociedade Brasileira de Economia e Sociologia Rural**. v.42, 2004.

ZABOROWICZ, M., BONIECKI, P., KOSZELA, K., PRZYBYLAK, A., PRZYBY?, J. Application of neural image analysis in evaluating the quality of greenhouse tomatoes. **Scientia Horticulturae**, v. 218, p. 222-229, 2017.

# ANÁLISE TEMPORAL DE DADOS DE NDVI PARA DEFINIÇÃO DE ZONAS DE MANEJO

Ricardo Sobjak<sup>1</sup>; Jackson Sieben<sup>2</sup>; Glaucio Jose Gomes<sup>3</sup>; Kelyn Schenatto<sup>1</sup>; Claudio Leones Bazzi<sup>1</sup>

<sup>1</sup>Computação (Dr. Engenharia Agrícola), Professor(a) - Universidade Tecnológica Federal do Paraná, Campus Medianeira, Medianeira, PR. ricardosobjak@utfpr.edu.br / (45) 9 9813-2650; <sup>2</sup>Ciência da Computação, Estudante - Universidade Tecnológica Federal do Paraná, Campus Medianeira, Medianeira, PR; <sup>3</sup>Químico, Pós-doutorado - Universidade Tecnológica Federal do Paraná, Campus Medianeira, Medianeira, PR

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** O delineamento de zonas de manejo (ZM) tem se tornado uma prática no contexto de agricultura de precisão (AP), considerando que trata-se de um método reconhecido e economicamente viável, mesmo para pequenos produtores. Dentre os dados utilizados para o delineamento destas sub-regiões do talhão, verifica-se o uso de atributos físicos e topográficos da área (ZMs permanentes) e atributos de solo e planta (ZMs variáveis). Considerando viabilizar o delineamento de ZMs por meio de dados de sensoriamento remoto, o presente trabalho buscou avaliar o aspecto temporal dos dados de NDVI de uma área experimental cultivada com soja em função da resposta da cultura. Os resultados apresentaram que o NDVI pode ser utilizado para identificação de locais com potenciais produtivos distintos, servindo como um indicador de produtividade.

**PALAVRAS-CHAVE:** sensoriamento remoto; índice de vegetação; variabilidade espacial

## TEMPORAL ANALYSIS OF NDVI DATA FOR DEFINITION OF MANAGEMENT ZONES

**ABSTRACT:** Management zones (MZ) have become a constant practice in the context of precision agriculture, considering that it is a validated and economically viable method, even for small producers. Among the data used for delineating these sub-regions of the field, there is the use of physical and topographic attributes of the field (permanent MZs) and soil and plant attributes (variable MZs). Therefore, the present work sought to evaluate the temporal aspect of NDVI data from an experimental field cultivated with soybean as a function of the response of the crop, considering the feasibility of the design of MZs through remote sensing data. The results showed that the NDVI could be used to identify places with different productive potential, serving as an indicator of productivity.

**KEYWORDS:** remote sensing; vegetation index; spatial variability

**INTRODUÇÃO:** A variabilidade do solo é consequência de complexas interações dos fatores e processos de sua formação, porém agentes externos podem influenciar e alterar seus atributos, como por exemplo, as características climáticas, irrigações, correções, práticas de manejo do solo e da cultura (Davatgar et al., 2012). Portanto, não é incomum o conteúdo, a distribuição e a disponibilidade de nutrientes do solo variar amplamente tanto dentro como entre os campos (Corwin and Lesch, 2003). Como a variabilidade espacial dos atributos químicos e físicos do solo influencia na qualidade dos produtos agrícolas, bem como na produção de um modo geral, a agricultura de precisão (AP) aborda a sua variabilidade e a dos demais fatores que influenciam no rendimento das culturas (Teixeira et al., 2011).

Na AP, a elaboração e análise de mapas temáticos tornam possível o conhecimento da variabilidade dos diversos atributos do solo, planta e produtividade (Bazzi et al., 2015). Dessa forma, é uma das fases necessárias para auxiliar no processo de tomada de decisão por parte do produtor (Grego et al., 2014). Com base na análise de um mapa temático de produtividade que representa a variabilidade espacial das características da lavoura, é possível intervir na produção dos anos posteriores por meio da aplicação diferenciada de insumos (Spezia et al., 2012), e por meio da confecção de mapas resultantes de amostragem georreferenciada é possível realizar o monitoramento da fertilidade do solo (Shiratsuchi et al., 2007), permitindo assim, otimizar a utilização de recursos através da aplicação de insumos e manejos localizados (Zhang et al., 2008). Como resultado, as

práticas de manejo agrícola realizadas de forma localizada trazem a promessa de reduzir o impacto ambiental, aumentar a produtividade e os retornos financeiros (Intarapapong, Hite, & Reinschmiedt, 2003).

Neste sentido, muitos trabalhos têm avaliado a possibilidade de utilizar zonas de manejo (ZM) para que máquinas e equipamentos tradicionais não sejam necessariamente substituídos e visando otimizar e reduzir custos da amostragem (Bazzi et al., 2021; Borges et al., 2020). Visando proporcionar uma visão simplificada para avaliação e estimação da produtividade em função de tecnologias para sensoriamento remoto, o presente trabalho objetivou a avaliação temporal de índices NDVI, obtidos por veículo aéreo não tripulado (VANT), em uma área experimental cultivada com soja, durante todo o ciclo vegetativo (uma coleta de dados semanal), visando a definição de ZMs.

**MATERIAIS E MÉTODOS:** A pesquisa tem sido realizada em um campo experimental no município de Céu Azul (Figura 1), com aproximadamente 25 ha<sup>-1</sup>, oeste do estado de Paraná, Brasil, nas coordenadas 25° 06'40.8"S 53°50'08.3"N onde a precipitação pluviométrica anual varia de 1.100 a 1.920 mm ano<sup>-1</sup> e uma temperatura média anual entre 15 e 24 °C (Aparecido et al., 2016). A cultura implantada na safra 2021/2022 foi a soja, semeada no mês de outubro de 2021.





Figura 1. Área experimental localizada no município de Céu Azul.

Após a semeadura da soja, foi realizado semanalmente, um voo com um VANT, conforme ilustra a Figura 2, seguindo ensaio pré-determinados pelo grupo de pesquisa.

## Semeadura




Figura 2. Fluxo de trabalho realizado para coleta dos dados à campo.

Nesse trabalho usou-se o VANT modelo Spectral (Figura 3b), fabricado pela empresa Nuvem UAV, equipado com uma câmera de alta resolução do modelo Altum (Figura 3a), da fabricante Micasense. O plano de voo foi realizado fazendo uso do software NControl, fornecido pelo fabricante do VANT, sendo que por meio deste software, foi possível além da elaboração do plano de voo, realizar o monitoramento da operação de coleta das imagens e comando de cada missão executada, bem como as configurações necessárias para cada voo, incluindo parâmetros de sobreposição das imagens (60% frontal e 80% lateral), adequações do tipo de câmera e calibração de sensores.

A colheita foi realizada fazendo uso de uma colhedora modelo IH 2388, da marca Case (CASE IH, Sorocaba, Brazil), equipada com monitor de colheita AFS PRO 600 (Case IH, Racine, USA). Os dados foram filtrados conforme Michelin et al. (2007).



(a)



(b)

Figura 3. Equipamento utilizado para captura das imagens: a) Camera Altum da Micasense; 2) VANT: Drone Spectral da Nuvem UAV.

As imagens obtidas foram importados para o software Pix4D, sendo realizada a demarcação da região de interesse e então realizado o processamento do mosaico (Figura 4) por meio das imagens originais (entre 280 e 320 imagens para cada banda spectral), bem como o cálculo do índice de NDVI, a partir das bandas processadas. Feito isso, as imagens foram transformadas em superfícies com polígonos de 5x5 (25 m<sup>2</sup>) e

exportadas para o formato texto (extensão .txt) para padronizar as imagens e proporcionar um arquivo de entrada compatível com o software AgDataBox-Map (Borges et al., 2020).




Figura 4. Mapa de NDVI da área experimental (semana 07 – 31/12/2021), processado no software Pix4D.

Fazendo uso do software AgDataBox-Map, foram geradas para cada semana, 2, 3 e 4 zonas de manejo com os dados do índice NDVI, fazendo uso de algoritmos Fuzzy C-Means, visando verificar se tais zonas de manejo poderiam ser visualizadas como perspectiva de produção. Testes de comparação de média (ANOVA) e de redução da variância (RV) também foram executados a fim de validar a separação das zonas de manejo fazendo uso de dados de produtividade.



**RESULTADOS E DISCUSSÃO:** Para validação dos clusteres, avaliou-se os índices FPI (índice de performance fuzzy) e MPE (entropia da partição modificada), disponibilizados pelo algoritmo Fuzzy C-Means. A melhor opção de zona de manejo em cada conjunto de dados semanais foi definida em função da confirmação estatística da diferença média da produtividade entre as zonas (ANOVA), sendo que a melhor diferenciação entre clusters apresentada foi a da semana 13, indicando que houve uma melhor separação dos dados em função dos índices de NDVI utilizados. No gráfico apresentado na Figura 5, verifica-se que para todos os casos, a definição de 2 ZM foi a melhor opção para todos os casos, sendo que a definição de 4 ZM não foi apresentada no referido gráfico, considerando que a mesma não apresentou diferença de produtividade significativa, conforme teste da ANOVA.




Figura 5. Índices FPI e MPE utilizados para validação dos clusteres.

Conforme pode ser verificado na Tabela 1, para o zoneamento em duas zonas, todas apresentaram diferença significativa de produtividade, incluindo as zonas geradas logo nas primeiras semanas.

Tabela 1. Avaliação das zonas de manejo em função da produtividade

	<b>Semana1</b>		<b>Semana 2</b>		<b>Semana3</b>		<b>Semana4</b>	
	<b>Zona 1</b>	<b>Zona 2</b>	<b>Zona 1</b>	<b>Zona 2</b>	<b>Zona 1</b>	<b>Zona 2</b>	<b>Zona 1</b>	<b>Zona 2</b>
Média	6.7	6.2	6.82	6.46	6.43	6.76	6.44	6.71
Anova	a	b	a	b	b	a	b	a
	<b>Semana5</b>		<b>Semana6</b>		<b>Semana7</b>		<b>Semana8</b>	
	<b>Zona 1</b>	<b>Zona 2</b>	<b>Zona 1</b>	<b>Zona 2</b>	<b>Zona 1</b>	<b>Zona 2</b>	<b>Zona 1</b>	<b>Zona 2</b>
Média	6.60	6.05	6.58	6.04	6.03	6.58	6.17	6.56
Anova	a	b	a	b	b	a	b	a
	<b>Semana9</b>		<b>Semana10</b>		<b>Semana11</b>		<b>Semana12</b>	
	<b>Zona 1</b>	<b>Zona 2</b>	<b>Zona 1</b>	<b>Zona 2</b>	<b>Zona 1</b>	<b>Zona 2</b>	<b>Zona 1</b>	<b>Zona 2</b>
Média	6.56	6.23	5.98	6.57	5.99	6.57	6.53	6.37
Anova	a	b	b	a	b	a	a	b
	<b>Semana13</b>		<b>Semana14</b>		<b>Semana15</b>			
	<b>Zona 1</b>	<b>Zona 2</b>	<b>Zona 1</b>	<b>Zona 2</b>	<b>Zona 1</b>	<b>Zona 2</b>		
Média	6.53	6.19	6.82	6.37	6.12	6.83		
Anova	a	b	a	b	b	a		

Apesar dos resultados apresentarem-se como promissores, a fragmentação dos dados torna uma tarefa difícil de operacionalização. Conforme apresentado na Figura 6, em que se tem a definição dos pixels que representam cada ZM e a localização dos pontos em que a colhedora trafegou realizando a colheita, pode-se verificar que não foi possível a definição de áreas homogêneas de NDVI, pois se mostrou bastante fragmentada. Isso pode ter ocorrido pela estiagem e falhas de plantio, que acabaram por afetar a produtividade da cultura.



Figura 6. Mapa de duas zonas de manejo, fazendo uso de NDVI e sobreposição dos caminhos percorridos pela colhedora e pontos de coleta de dados de produtividade.

**CONCLUSÃO:** Verificou-se que os dados de vegetação podem ser utilizados no contexto de geração de zonas de manejo para estimativa da produtividade da soja, bem como definir locais em que há perda de produtividade em função de problemas nutricionais das plantas. Verificou-se que as zonas de manejo geradas entre a quinta e a décima terceiras semanas apresentaram maior facilidade no processo de agrupamento, obtendo-se melhores resultados.

**AGRADECIMENTOS:**

Os autores agradecem o Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e ao Parque Tecnológico Itaipu – FPTI/BR e à Fundação Araucária pelo aporte financeiro e a

concessão de bolsas de estudo e materiais utilizados na construção do protótipo. À Universidade Tecnológica Federal do Paraná - *Campus* Medianeira pelo suporte referente a pesquisa desenvolvida.

#### REFERÊNCIAS

- APARECIDO, L.E.D.O.; ROLIM, G.D.S.; RICHETTI, J.; SOUZA, P.S.D.; JOHANN, J.A. Köppen, Thornthwaite and Camargo climate classifications for climatic zoning in the State of Paraná, Brazil. **Ciência e Agrotecnologia**, v.40, p.405–417, 2016.
- BAZZI, C.L.; MARTINS, M.R. ; CORDEIRO, B.E.; GEBLER, L.; DE SOUZA, E.G.; SCHENATTO, K.; PAULA FILHO, P. L.; SOBJAK, R. Yield map generation of perennial crops for fresh consumption. **Precision Agriculture**, v.23, p.698–711, 2021.
- BAZZI, C.L.; SOUZA, E.G.; BETZEK, N.M.; SDUM Software para definição de unidades de manejo: Teoria e Prática. First edit. ed. PGEAGRI, Cascavél, 2015.
- BORGES, L.; BAZZI, C.L. ; DE SOUZA, E.G.; MAGALHAES, P.S.G.; MICHELON, G.K. Web software to create thematic maps for precision agriculture. **Pesquisa Agropecuária Brasileira (online)**, v.55, p.1-11, 2020.
- CORWIN, D.L.; LESCH, S.M. 2003. Application of soil electrical conductivity to precision agriculture: Theory, Principles and Guidelines. **Agronomy Journal**, v.95, p.455–519, 2003.
- DAVATGAR, N.; NEISHABOURI, M.R.; SEPASKHAH, A.R. 2012. Delineation of site specific nutrient management zones for a paddy cultivated area based on soil fertility using fuzzy clustering. **Geoderma**, v.173–174, p.111–118, 2012.
- GREGO, C.R.; OLIVEIRA, R.P. DE; VIEIRA, S.R. Geoestatística aplicada a Agricultura de Precisão, in: Agricultura de Precisão Resultado de Um Novo Olhar. pp. 74–83, 2014.
- INTARAPAPONG, W.; HITE, D.; REINSCHMIEDT, L. Water quality impacts of conservation agricultural practices in the Mississippi Delta. **Journal of the American Water Resources Association**, 38, p.507–515, 2002.
- MICHELAN, R.; SOUZA, E. G.; URIBE-OPAZO, M.A. Determinação e remoção do tempo de atraso em mapas de colheita de milho. **Acta Scientiarum(Human and Social Sciences)**, v.29, p.147-155, 2007.
- SHIRATSUCHI, L.S.; MARCHÃO, R.L.; JERKE, C.; RESENDE, A.V.; FONTES, J.R.A.; OLIVEIRA, C.M. Geração mapas multitemáticos agricultura de precisão. Boletim de Pesquisa e Desenvolvimento, EMBRAPA, Planaltina – DF, n.181 p.22, 2007.
- SPEZIA, G.R. SOUZA, E.G. DE; NÓBREGA, L.H.P.; URIBE-OPAZO, M.A.; MILAN, M.; BAZZI, C.L. Model to estimate the sampling density for establishment of yield mapping. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.16, p.449-457, 2012.
- TEIXEIRA L. A. J.; J. A QUAGGIO; E. V. MELLIS. Enhancing Nutrient Use Efficiency In Banana Tree Under Irrigation And Fertigation. **Revista Brasileira de Fruticultura**, v.33, p.272-278, 2011.
- ZHANG, M.; LI, M.Z.; LIU, G.; WANG, M.H. Yield Mapping in Precision Farming. In: Li, D. (eds) Computer And Computing Technologies In Agriculture, Volume II. CCTA 2007. The International Federation for Information Processing, Springer, Boston, MA. v.259, p.1407–1410, 2008.

# DINÂMICA ESPAÇO-TEMPORAL DO ÍNDICE DE ÁREA FOLIAR DE CAFEIROS ESQUELETADOS ESTIMADO POR SENSORIAMENTO REMOTO AÉREO

Samuel de Assis Silva<sup>1</sup>; Marco Henrique Souza de Sá<sup>2</sup>; Levi Fraga Pajehú<sup>3</sup>; Julião Soares de Souza Lima<sup>4</sup>

<sup>1</sup>Eng. Agrônomo, Professor - Depto. Engenharia Rural, CCAE, UFES, Alegre-ES. samuel.assilva@gmail.com / (28) 9 9988-2927; <sup>2</sup>Discente, Curso de Agronomia - Depto. Engenharia Rural, CCAE, UFES, Alegre-ES; <sup>3</sup>Eng. Agrônomo, Dourotando - PPGAG, CCAE, UFES, Alegre-ES; <sup>4</sup>Eng. Agrícola, Professor - Depto. Engenharia Rural, CCAE, UFES, Alegre-ES

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Como esse trabalho se objetivou avaliar o comportamento espaço-temporal do índice de área foliar (IAF) de plantas de café submetidas à poda por esqueletamento, visando avaliar a capacidade e eficiência de rebrota das plantas e reconstituição da copa. O estudo foi desenvolvido em uma lavoura comercial de café arábica microterraceada, localizada no município de Ibatiba, no estado do Espírito Santo. O sensor multiespectral embarcado em veículo aéreo não tripulado (VANT) foi utilizado para realizar leituras de reflectância nos comprimentos de onda do vermelho (Red) e do infravermelho próximo (NIR). Com os resultados, foi calculado o índice de SAVI e estimado o IAF. A evolução temporal do IAF foi avaliada pelo coeficiente de correlação linear de Pearson ao nível de 5% e os coeficientes de desvio relativo (CDR). O IAF e SAVI apresentaram aumento em todo período analisado, entretanto, a correlação linear de Pearson indicou correlação linear positiva apenas em fevereiro-maio e maio-julho. A análise CDRm para o SAVI e IAF demonstrou maior vigor vegetativo de dezembro-fevereiro. Contudo concluiu-se que as plantas de café apresentaram uma rebrota eficiente, com maior reconstituição da copa no período de dezembro-fevereiro e certa estabilidade nos períodos de fevereiro-maio e maio-julho.

**PALAVRAS-CHAVE:** Cafeicultura; Sensores; Agricultura digital

## SPATIAL AND TEMPORAL DYNAMICS OF THE LEAF AREA INDEX OF PRURN COFFEE TREES ESTIMATED BY AERIAL REMOTE SENSING

**ABSTRACT:** As this work aimed to evaluate the spatio-temporal behavior of the leaf area index (LAI) of coffee plants submitted to pruning by skeleton, aiming to evaluate the capacity and efficiency of plant regrowth and crown reconstitution. The study was carried out in a commercial microterrace arabica coffee plantation, located in the municipality of Ibatiba, in the state of Espírito Santo. The multispectral sensor onboard an unmanned aerial vehicle (UAV) was used to perform reflectance readings in the red (Red) and near infrared (NIR) wavelengths. With the results, the SAVI index was calculated and the LAI was estimated. The temporal evolution of the LAI was evaluated by Pearson's linear correlation coefficient at the 5% level and the relative deviation coefficients (CDR). The LAI and SAVI increased throughout the analyzed period, however, Pearson's linear correlation indicated a positive linear correlation only in February-May and May-July. The CDRm analysis for SAVI and IAF showed higher vegetative vigor from December to February. However, it was concluded that the coffee plants showed an efficient regrowth, with greater crown reconstitution in the period of December-February and some stability in the periods of February-May and May-July.

**KEYWORDS:** Coffee growing; Sensors; Digital Agriculture

**INTRODUÇÃO:** O uso da tecnologia de sensoriamento remoto no campo tem se tornado cada vez mais comum, sendo utilizada como ferramenta na gestão da agricultura de precisão, devido a facilidade para se fazer o monitoramento da cultura (PEI et al., 2014). O avanço na tecnologia tornou possível a estimativa dos atributos biofísicos das culturas sem a necessidade de retirar partes da planta, graças ao desenvolvimento de sensores de dossel (DIACONO et al., 2013). O sensoriamento remoto permite obter dados de reflectância espectral que podem ser utilizados para monitorar o status do crescimento da cultura por meio de vários parâmetros biofísicos, fisiológicos ou bioquímicos da cultura.



O índice de área foliar (IAF) é um dos principais parâmetros utilizados no monitoramento da cultura, definido por Watson (1947) como a razão entre a área foliar do dossel das plantas e a unidade de superfície projetada no solo ( $m^2 m^{-2}$ ). Trata-se de uma variável biofísica que relaciona, intimamente, a transpiração e a produtividade do ecossistema.

O índice de vegetação com diferença normalizada (NDVI) vem sendo utilizado para estimar o IAF, porém em algumas situações ele tem apresentado sensibilidade a variações do solo e dessa forma, não consegue obter uma boa representatividade na inferência do IAF (ALMEIDA et al., 2015). Para reduzir o a refletância do solo na estimativa do IAF pelo NDVI, Huete (1988) desenvolveu o índice de vegetação ajustado ao solo (SAVI), em que se utilizam as mesmas bandas do NDVI, porém com um deslocamento dos eixos espectrais, onde se incorporou o fator L, na qual é definido de acordo com as características dos solos e o tipo de cobertura, podendo variar entre 0 (vegetação densa) e 1 (vegetação rala).

A utilização desses índices pode auxiliar no monitoramento da evolução espaço-temporal do vigor vegetativo das plantas, em especial daquelas submetidas a poda. A poda é uma técnica muito realizada pelos cafeicultores, para corrigir a arquitetura das plantas, controle de pragas e doenças, recuperação das plantas fora dos padrões técnicos e econômicos desejáveis, para a manutenção da capacidade produtiva, e para reduzir o efeito da alternância de produção (JAPIASSU, 2010; PEREIRA et al., 2007, 2013; QUEIROZ-VOLTAN et al., 2006). A poda traz muitos benefícios a longo prazo, entretanto a curto prazo ela causa alterações no IAF e redução do sistema radicular, sendo necessário um período para que as plantas se recuperem e retornem a produção. Pouco ainda se sabe sobre estimativa acerca da capacidade e eficiência da rebrota dos cafezais que foram submetidos a poda a partir do IAF. Portanto, o trabalho traz contribuições inéditas, avaliando a capacidade e a eficiência de rebrota e a reconstituição da copa de plantas de café que foram submetidas a poda do tipo esqueletamento.

Com esse trabalho se objetivou avaliar o comportamento espaço-temporal do índice de área foliar (IAF) de plantas de café submetidas à poda por esqueletamento, visando avaliar a capacidade e eficiência de rebrota das plantas e reconstituição da copa.

**MATERIAIS E MÉTODOS:** O estudo foi realizado em uma lavoura comercial de café arábica localizada no município de Ibatiba, na Microrregião de Planejamento do Caparaó, no estado do Espírito Santo. O experimento foi conduzido em uma área inclinada onde foi realizado o nivelamento das entrelinhas de plantio de café através do que tem sido conhecido como microterraceamento. O solo da lavoura foi classificado com o Sistema Brasileiro de Classificação de Solo (SANTOS et al., 2018) como Latossolo Vermelho-Amarelo.

A lavoura foi conduzida em sistema convencional de manejo, onde o manejo ocorre em ciclos de três anos de produção e um ano de reforma vegetativa. Nesse sistema, após a terceira safra as plantas são submetidas a poda por esqueletamento para renovação da lavoura. Desta forma o esqueletamento se deu imediatamente após a colheita da safra 2019/2020.

Para atender aos objetivos propostos na pesquisa foram realizadas coletas de imagens aéreas da área em estudo a cada dois meses. Os aerolevantamentos foram realizados buscando-se contemplar as fases fenológicas do cafeeiro durante um ano agrícola.

Utilizou-se um sensor ótico multiespectral RedEdge MX equipado com lentes 47.9° HFOV 5.4 mm, que captura segmentos dos comprimentos de onda do espectro eletromagnético do visível (R, G e B), do RedEdge e do infravermelho próximo (NIR). Esse equipamento é acompanhado de um sensor solar DLS2 com GPS incorporado, com 12 canais para capturar a incidência de radiação solar em diferentes ângulos. Este sensor auxiliou a calibração radiométrica das imagens.

Os sensores foram embarcados em um VANT multirotor modelo Inspire 2, em um suporte específico que foi desenvolvido em impressora 3D. Os voos automatizados foram realizados bimestralmente respeitando a janela de voo de 11 às 13h e seguindo planejamento pré-estabelecido. Os voos foram realizados a uma altura máxima de 120 m e o número de cenas (imagens) obtidas por voo, bem como a velocidade e as sobreposições laterais e horizontais foram definidas após testes preliminares.

Calibrações geométricas das imagens foram realizadas para eliminar distorções causadas pelas características internas da câmera. As calibrações radiométricas foram realizadas para converter os números digitais (ND) para valores físicos de reflectância. As calibrações radiométrica foram realizadas a partir da resposta espectral de alvos de referência espalhados por toda a extensão da área e também a partir dos acessórios de calibração de imagens que acompanham o sensor multiespectral.

As imagens calibradas foram processadas para obtenção dos mosaicos de ortofotos (ortomosaicos) utilizando o software livre OpenDroneMap (Drone Mapping Software). Utilizou-se 15 pontos de controle fotointerpretáveis distribuídos de forma estratégica por toda a extensão da área, para aumentar a precisão posicional dos ortomosaicos. Os pontos de controle foram georreferenciados utilizando um receptor GNSS de precisão subcentimétrica.

O IAF estimado depende do cálculo do índice de vegetação ajustado ao solo (SAVI). O SAVI é um índice derivado do NDVI (Índice de vegetação da diferença normalizada) e que leva em consideração os efeitos do solo exposto nas imagens analisadas e é utilizado para situações em que a superfície não está completamente coberta pela vegetação. Esse índice foi estimado pela equação:

$$SAVI = \frac{(1 + L_s)(NIR - R)}{(L_s + NIR + R)} \quad (1)$$

em que:  $L_s$  = constante de fator de ajuste;  $NIR$  = valores de reflectância na banda do infravermelho próximo, e;  $R$  = valores de reflectância na banda do vermelho (red). O  $L_s$  é uma constante dependente da cobertura do solo e varia de 0,25 a 1,0. Segundo Huete (1988), um valor igual: a 0,25 é utilizado para vegetações densas; a 0,5 para uma vegetação intermediária, e; a 1,0 é utilizado para vegetação com baixa densidade. Quando os valores de  $L_s$  são iguais a zero os resultados de SAVI e NDVI são iguais, sendo utilizado, em média, um  $L_s$  igual a 0,5.

A partir dos valores de SAVI foram calculados os valores de IAF. O IAF é definido como um índice biofísico calculado pela razão entre a área foliar de uma vegetação por unidade de área utilizada por esta vegetação, sendo um indicador da biomassa de cada pixel da imagem, calculado pela equação proposta por Allen et al. (2002):

$$IAF = \frac{\ln\left(\frac{0.69 - SAVI}{0.59}\right)}{0.91} \quad (1)$$

Os valores 0,69, 0,59 e 0,91 são as constantes utilizadas para o cálculo que visam corrigir os valores de SAVI para valores biofísicos.

A evolução temporal do IAF e, conseqüentemente da capacidade de rebrota das plantas, foi avaliada utilizando:

a) Coeficiente de correlação linear de Pearson ao nível de 5% de probabilidade - essa análise foi utilizada para descrever a estabilidade espaço-temporal dos valores de IAF. Por não ser influenciado pelos valores absolutos, o coeficiente de Pearson permite avaliar se a distribuição espacial dos valores do índice se mantem ao longo tempo;

b) Coeficientes de desvios relativos. Essa análise foi utilizada para descrever as variações pontuais e médias dos valores absolutos do IAF ao longo do tempo. Para isso foram calculados os coeficientes de desvios relativos pontual (CDRi) e médio (CDRm). O CDRi e o CDRm foram calculados conforme as seguintes equações:

$$CDRi = \left(\frac{IAF_i - IAF_{i-1}}{IAF_{i-1}}\right) * 100 \quad (2)$$

$$CDRm = \sum_{i=1}^n |CDRi| / n \quad (3)$$

Em que:  $CDR_i$  = coeficiente de desvio relativo pontual (%);  $CDR_m$  = coeficiente de desvio relativo médio absoluto (%);  $n$  = número de pontos amostrais;  $IAF_i$  = IAF em cada ponto do mapa no período  $i$ ;  $IAF_{i-1}$  = IAF em cada ponto do mapa no período  $i-1$ .

**RESULTADOS E DISCUSSÃO:** A Figura 1 apresenta os box-plots dos valores do SAVI e IAF que foram obtidos a partir das imagens do sensoriamento remoto aéreo. Nos gráficos é possível observar a amplitude interquartílica, a mediana e os valores discrepantes. Com a construção dos gráficos para os diferentes aerolevantamentos é possível observar variabilidade temporal entre os valores de SAVI e IAF.




FIGURA 1. Box-plot do SAVI e do IAF mensurados com sensoriamento remoto aéreo em lavoura cafeeira microterraceada. **Box-plot of SAVI and IAF measured with aerial remote sensing in microterrace coffee plantations.**

Analisando os índices de SAVI e IAF é possível observar um aumento nos valores com o passar dos meses mensurados, tanto para os valores medianos quanto para o intervalo de ocorrência, com exceção dos valores mensurados no SAVI em fevereiro 2021 comparado a maio 2021, onde o aumento só ocorreu para a mediana. Este aumento já era esperado, visto que após a poda as plantas de café reconstituíram sua parte aérea, levando ao aumento tanto para o índice de SAVI quanto para o IAF.

Os resultados do processamento das imagens para o SAVI e do IAF nos períodos de dezembro 2020 e fevereiro 2021 são apresentados na Figura 2.

Sabendo que o índice de SAVI é um indicador da biomassa para cada pixel, o mapa apresenta como valores mais baixos as áreas com uma vegetação mais rala ou solo exposto (0,00 e 0,19), os valores intermediários são as áreas com vegetação relativa (0,38) e os maiores valores do SAVI são áreas com uma vegetação mais densa (0,56 e 0,75). No primeiro mapa do SAVI referente a dezembro 2020 os pixels predominam nas escalas de 0,00 e 0,19 no mapa, demonstrando que o valor de SAVI se encontra próximo de zero. Isso caracteriza a vegetação como rala, isso se dá devido ao pouco tempo após a realização da poda e também por conta das áreas de solo expostos nas entrelinhas do cafezal.

O SAVI referente a dezembro de 2020 é inferior quando comparado ao encontrado por Albuquerque Wanderley et al., (2017) para vegetação da caatinga na escarpa da Serra do Teixeira no norte do rio Taperoá entre 0,26 e 0,38, em uma área predominantemente de afloramentos rochosos, além de algumas áreas de solo exposto e vegetação esparsa.

Já o segundo mapa do SAVI referente a fevereiro 2021 apresenta um aumento no número de pixels das escalas de 0,38; 0,56 e 0,75 demonstrando que houve um aumento no adensamento da vegetação devido a recomposição do dossel das plantas de café que haviam sido podadas. Comparando ao índice de SAVI de 0,7 encontrado por Gameiro et al. (2017) durante a frutificação de fruteiras irrigadas, apenas em alguns pixels do mapa as plantas de café se equiparam.

O mapa do IAF assim como o SAVI é um indicador de biomassa de cada pixel da imagem, os valores mais baixos representam as áreas com uma vegetação mais rala ou solo exposto (0,0 e 0,8), os valores intermediários representam áreas com relativa vegetação (1,5) e os maiores valores do IAF são áreas com uma vegetação mais densa (2,3 e 3,0). A variação temporal do IAF apresenta distribuição semelhante aos mapas do SAVI, isso ocorreu devido ao IAF ser um subproduto do SAVI. O mapa do IAF referente a dezembro 2020 apresenta como predominância pixels próximos da escala 0, devido a poda por esqueletamento ter sido realizada recentemente. Chicaneli (2019) realizando uma análise no IAF da cultura do tomate, observou que com 5 dias após o plantio, o IAF do tomate também se encontrava abaixo de 0,5 por conta do baixo porte da cultura e parte do solo estar descoberto, estes mesmos motivos explicam o IAF encontrado nas plantas de que café recentemente podadas, que da mesma forma apresentavam baixo porte e solo relativamente descoberto.

Já no mapa do IAF referente a fevereiro 2021 é possível observar um aumento no número de pixels das escalas de 0,8; 1,5 e alguns pixels na escala de 2,3 que antes não estavam presentes, comprovando que houve um aumento significativo no IAF em relação à última medição. O mesmo foi observado por Chicaneli (2019) para o tomateiro, 37 dias após o plantio as plantas se encontravam na fase de crescimento fazendo com que o aumento da área foliar ocorresse mais intensamente e o IAF estivesse acima de 0,5.

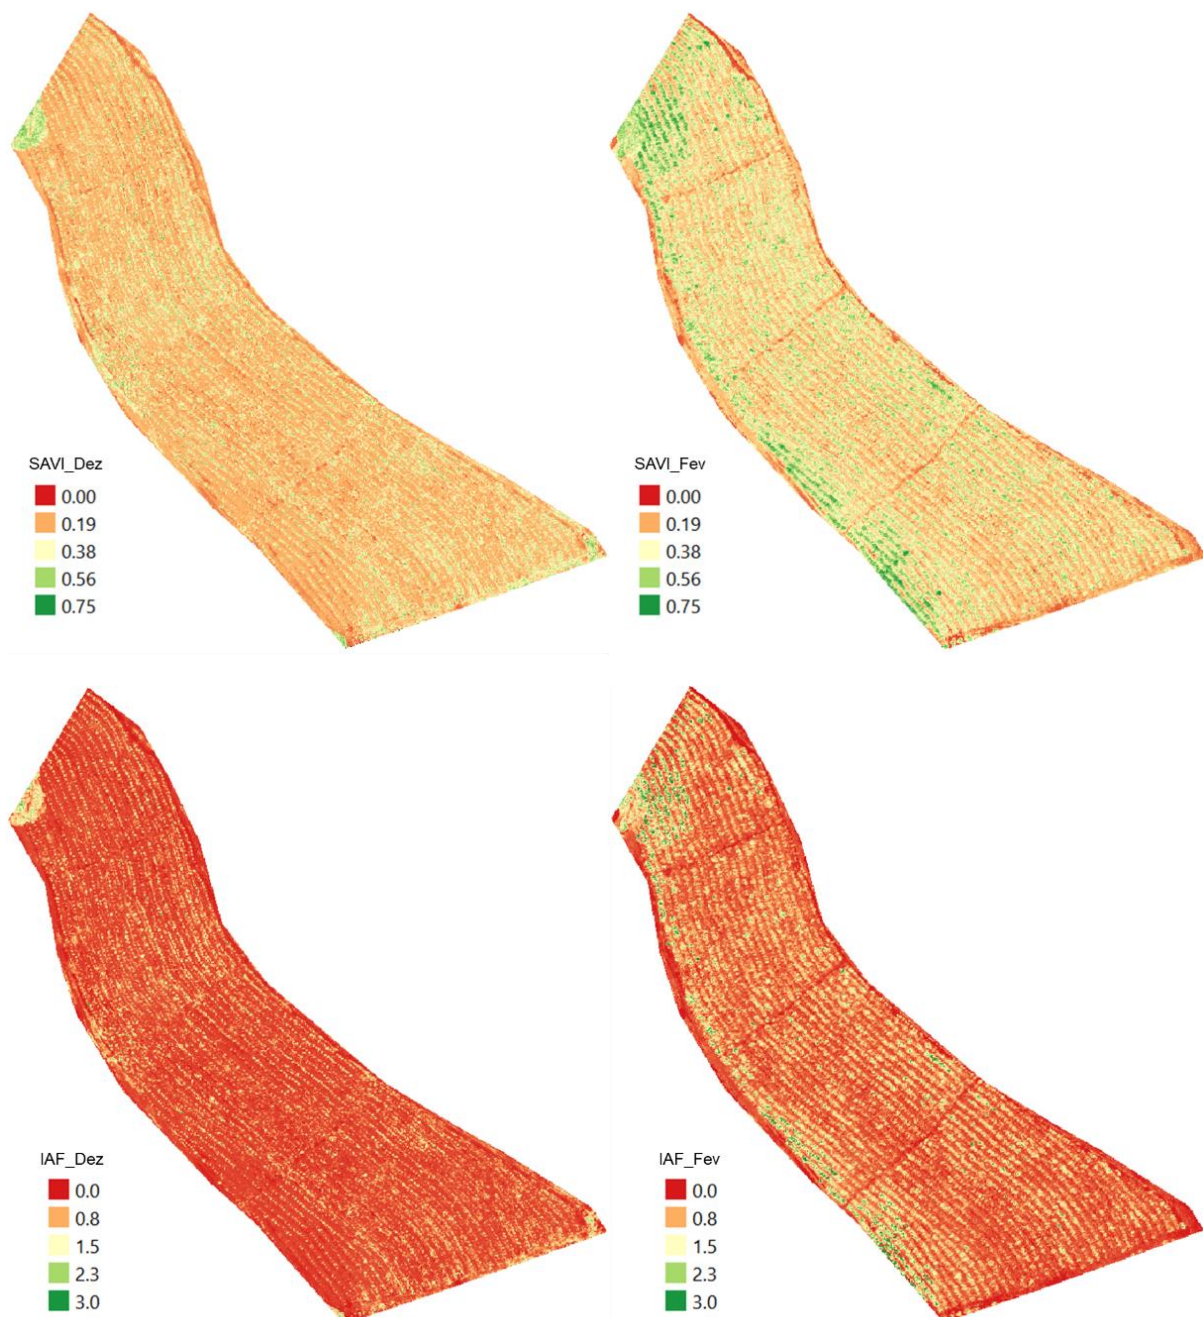


FIGURA 2. Mapas temáticos da variação temporal do SAVI e do IAF em duas diferentes datas dentro do período de estudo. **Thematic maps of the temporal variation of SAVI and IAF on two different dates within the study period.**

A correlação linear entre os valores de SAVI e IAF entre os diferentes períodos de estudo estão apresentadas na Figura 3. Considerando a classificação do coeficiente de correlação linear de Pearson de Dancy e Reidy (2005) onde  $r = 0,10$  até  $0,30$  (fraco);  $r = 0,40$  até  $0,60$  (moderado);  $r = 0,70$  até  $1$  (forte). Analisando o coeficiente de correlação linear de Pearson do SAVI para período de dezembro de 2020 e fevereiro de 2021, o valor de  $r = -0,0704$  indica uma correlação linear negativa fraca, entretanto, seu p-valor é maior que 5%, indicando que hipótese de que o coeficiente de correlação seja igual a zero foi aceita, não existindo uma relação significativa entre os meses testados. Já o coeficiente de correlação linear de Pearson do SAVI para período de fevereiro em relação a maio de 2021 e maio em relação a julho de 2021 apresentaram respectivamente  $r$  de  $0,4081$  (correlação positiva moderada) e  $0,2442$  (correlação positiva fraca), e o p-valor de ambos foi menor que 5%. Portanto existe correlação linear positiva e significativa entre os períodos de fevereiro-maio e maio-julho, ou seja, conforme os valores de SAVI do primeiro período aumentam o SAVI do período subsequente também tiveram um aumento.

Assim como o SAVI o p-valor do IAF do período de dezembro de 2020 e fevereiro de 2021 foi maior que 5% indicando que hipótese de que o coeficiente de correlação linear seja igual a zero foi aceita, não existindo uma relação significativa entre estes períodos. Já o coeficiente de correlação linear de Pearson do IAF para período de fevereiro em relação a maio de 2021 e maio em relação a julho de 2021 apresentaram respectivamente  $r$  de  $0,4005$  (correlação positiva moderada) e  $0,2733$  (correlação positiva fraca), com o p-valor de ambos menores que 5%. Portanto existe correlação linear positiva e significativa entre os períodos de fevereiro-maio e maio-julho, ou seja, conforme os valores do IAF do primeiro período aumenta o IAF do período subsequente também sofreram um aumento.




FIGURA 3. Correlação linear entre os valores de SAVI e IAF entre os diferentes períodos de estudo. **Linear correlation between SAVI and LAI values between different study periods.**

Na Figura 4 estão descritos os coeficientes de desvios relativos pontuais (CDRi) e médios (CDRm) entre a relação do SAVI mensurado em diferentes períodos. A Figura 4A apresenta a comparação do mês de fevereiro de 2021 com o mês de dezembro de 2020, onde se observa uma grande disparidade entre estes períodos, com CDRi variando de quase 200% até próximo de -50% e CDRm de aproximadamente 40%. Embora em alguns pontos o valor de SAVI tenha reduzido de dezembro para fevereiro, na média houve um aumento de aproximadamente 40% no período descrito.

A Figura 4B apresenta a comparação do mês de maio com o mês de fevereiro de 2021, neste caso a diferença entre os períodos foi um pouco menor em relação ao anterior, com CDRi variando de quase 100% até próximo de -20% e CDRm de aproximadamente 25%. Embora em alguns pontos o valor de SAVI tenha reduzido de fevereiro para maio, na média houve um aumento de aproximadamente 25% no período descrito.

A Figura 4C apresenta a comparação do mês de julho com mês de maio de 2021, neste caso a diferença entre os períodos foi parecida com a Figura B, com CDRi variando de quase 80% até próximo de -20% e CDRm de



aproximadamente 20%. Embora em alguns pontos o valor de SAVI tenha reduzido de maio para julho, na média houve um aumento de aproximadamente 20% no período descrito.

Analisando os valores de CDRm para o SAVI como um todo observa-se um maior vigor vegetativo de dezembro para fevereiro seguida de uma redução drástica de fevereiro para maio, seguido de uma estabilidade de maio para julho. Esta redução pode ter ocorrido por se tratar do início do período de seca que se inicia geralmente em abril. Coltri et al., (2011), encontraram resultados semelhantes, com plantas de café apresentando redução dos valores de SAVI nos períodos de seca.

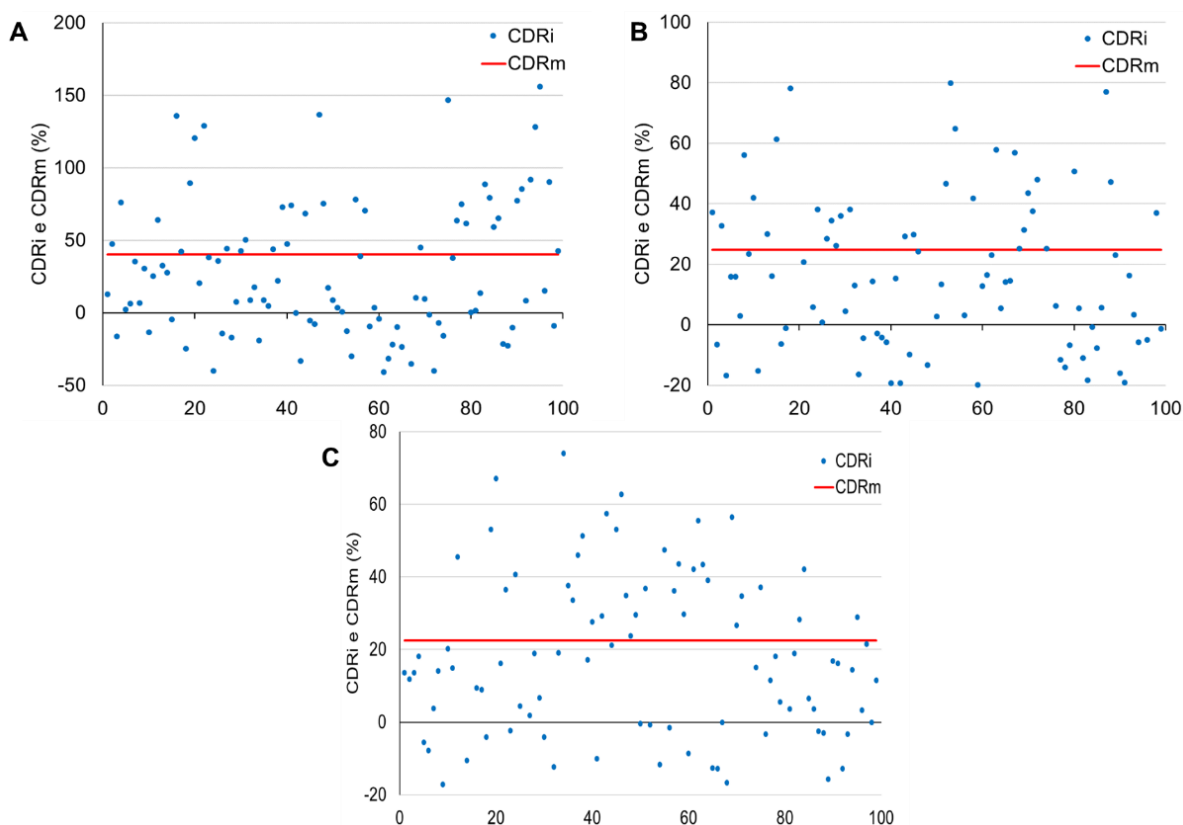


FIGURA 4. Coeficientes de desvios relativos pontuais (CDRi) e médios (CDRm) entre a relação do SAVI mensurado em diferentes períodos: A) relação Fev\_21:Dez\_2020; B) Maio\_21:Fev\_21, e; C) Jul\_21:Maio\_21. **Coefficients of point (CDRi) and average (CDRm) relative deviations between the SAVI ratio measured in different periods: A) Feb\_21:Dec\_2020 ratio; B) May\_21:Feb\_21, and; C) Jul\_21:May\_21.**

Na Figura 5 estão descritos os coeficientes de desvios relativos pontuais (CDRi) e médios (CDRm) entre a relação do IAF mensurado em diferentes períodos. A Figura 5A apresenta a comparação do mês de fevereiro de 2021 com o mês de dezembro de 2020, observa-se uma grande disparidade entre estes períodos, com CDRi variando de quase 550% até próximo de -50% e CDRm de aproximadamente 110%. Embora em alguns pontos o valor de IAF tenha reduzido de dezembro para fevereiro, na média houve um aumento de aproximadamente 110% no período descrito.

A Figura 5B apresenta a comparação do mês de maio com o mês de fevereiro de 2021, neste caso a diferença entre os períodos foi menor em relação ao anterior, com CDRi variando de quase 180% até próximo de -20% e CDRm de aproximadamente 55%. Embora em alguns pontos o valor de IAF tenha reduzido de fevereiro para maio, na média houve um aumento de aproximadamente 55% no período descrito.

A Figura 5C apresenta a comparação do mês de julho com mês de maio de 2021, apresentando uma grande diferença entre os períodos, com CDRi variando de aproximadamente 250% até próximo de -40% e CDRm de aproximadamente 55%. Embora em alguns pontos o valor de IAF tenha reduzido de maio para julho, na média houve um aumento de aproximadamente 55% no período descrito.

Analisando os valores de CDRm para o IAF como um todo, assim como o SAVI observou-se um maior vigor vegetativo de dezembro para fevereiro com o aumento IAF e uma redução drástica do vigor de fevereiro para maio e depois se estabilizou de maio para julho. A redução do vigor pode ter ocorrido por conta do déficit hídrico que afetou a capacidade de recuperação dos cafezais, o mesmo ocorreu com Coltri et al., (2011), confirmando que o vigor vegetativo varia conforme a variação das variáveis climáticas .

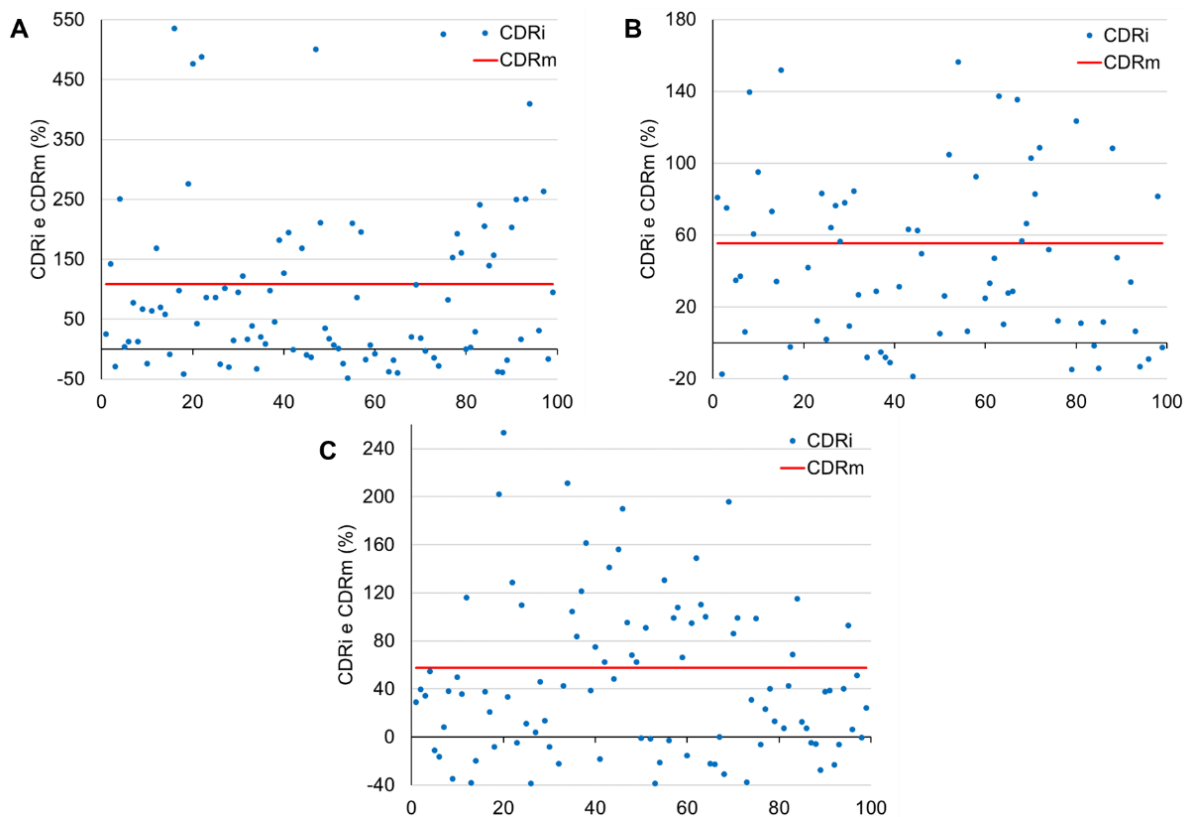


FIGURA 5. Coeficientes de desvios relativos pontuais (CDRi) e médios (CDRm) entre a relação do IAF mensurado em diferentes períodos: A) relação Fev\_21:Dez\_2020; B) Maio\_21:Fev\_21, e; C) Jul\_21:Maio\_21. **Coefficients of point relative deviations (CDRi) and average (CDRm) between the ratio of the LAI measured in different periods: A) ratio Feb\_21:Dec\_2020; B) May\_21:Feb\_21, and; C) Jul\_21:May\_21.**

A análise do comportamento do IAF e do SAVI no período de estudo demonstrou que houve uma maior rebrota dos cafezais de dezembro de 2021 a fevereiro 2020, algo esperado visto que as plantas de café em dezembro de 2020 haviam sido recentemente podadas e, portanto, qualquer evolução vegetativa seria significativa. Já no período de fevereiro a maio de 2021 ainda apresentava um índice considerável na rebrota dos cafezais, porém com uma redução considerável visto que no período anterior como as plantas estavam praticamente sem folhas qualquer crescimento seria significativo e, portanto, uma redução na velocidade de rebrota seria esperado no período subsequente, outro motivo para redução, porém menos significativo seria a limitação hídrica que se inicia neste período. Seguindo para o último período analisado de maio a julho, se constatou que o vigor vegetativo praticamente se manteve o mesmo do período anterior, devido a estabilização do crescimento vegetativo após recuperação parcial da copa das plantas.

**CONCLUSÃO:** O IAF das plantas de café submetidas à poda por esqueletamento foi crescente no período analisado, demonstrando uma rebrota eficiente dos cafezais.

O período de dezembro de 2020 a fevereiro de 2021 apresentou maior CDRm do IAF e conseqüentemente uma maior reconstituição da copa dos cafeeiros.

O CDRm dos períodos de fevereiro-maio e maio-julho apresentaram certa estabilidade, demonstrando semelhança no ritmo de crescimento vegetativo das plantas.

## AGRADECIMENTOS:

Ao CNPQ (Conselho Nacional de Desenvolvimento Científico e Tecnológico) e a FAPES (Fundação de Amparo à Pesquisa e Inovação do Espírito Santo) pelo financiamento para a execução do presente trabalho.

## REFERÊNCIAS

- ALBUQUERQUE WANDERLEY, L. S.; NÓBREGA, R. S.; MOREIRA, E. B.; ARAÚJO LUCENA, J. Variação dos Índices de Vegetação da Caatinga no alto curso da bacia hidrográfica do Rio Taperoá. **Os Desafios da Geografia Física na Fronteira do Conhecimento**, v. 1, p. 4988-5000, 2017.
- ALLEN, R.; TASUMI, M.; TREZZA, R. SEBAL Surface Energy Balance Algorithm for Land – Advanced Training and Users Manual – Idaho Implementation, version 1.0, 2002.
- ALMEIDA, A. Q. D.; RIBEIRO, A.; DELGADO, R. C.; RODY, Y. P.; OLIVEIRA, A. S. D.; LEITE, F. P. Índice de área foliar de Eucalyptus estimado por índices de vegetação utilizando imagens TM-Landsat 5. **Floresta e Ambiente**, 22, 368-376, 2015.
- CHICANELI, I. N. V. **Índice de área foliar por meio de sensoriamento remoto em pivô central na cultura do tomate**. Monografia de graduação (Bacharel em Agronomia) – Centro de Agronomia, Faculdade Evangélica de Goianésia, Goiás, 2019.
- COLTRI, P. P.; ROMANI, L. A. S.; DUBREUIL, V.; CORGNE, S.; ZULLO JUNIOR, J.; PINTO, H. S. Variação temporal da biomassa do café arábica arborizado e pleno sol, através de índices de vegetação. In: **Embrapa Informática Agropecuária-Artigo em anais de congresso (ALICE)**. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2011, Curitiba. Anais ... São José dos Campos: INPE, 2011., 2011.
- DANCEY, C.; REIDY, J. Estatística Sem Matemática para Psicologia: Usando SPSS para Windows. Porto Alegre, **Artmed**, 2006.
- DIACONO, M.; RUBINO, P.; MONTEMURRO, F. Manejo preciso de nitrogênio em trigo. Uma revisão. **Agronomia para o Desenvolvimento Sustentável**, v. 33, n. 1, pág. 219-241, 2013.
- FIGUEIREDO FILHO, D. B.; SILVA JÚNIOR, J. A. Desvendando os Mistérios do Coeficiente de Correlação de Pearson (r). **Revista Política Hoje**, v. 18, n. 1, p. 115-146, 2009.
- GAMEIRO, S.; TEIXEIRA, C. P. B.; SILVA NETO, T. A.; LOPES, M. F. L.; DUARTE, C. R.; SOUTO, M. V. S.; ZIMBACK, C. R. L. Avaliação da cobertura vegetal por meio de índices de vegetação (NDVI, SAVI e IAF) na Sub-Bacia Hidrográfica do Baixo Jaguaribe, CE. **Terræ**, v. 13, n. 1-2, pág. 15-22, 2016.
- HUETE, A. R. A índice de vegetação ajustado ao solo (SAVI). **Sensoriamento remoto do meio ambiente**, v. 25, n. 3, pág. 295-309, 1988.
- JACKSON, R. D.; HUETE, A. R. Interpretando índices de vegetação. **Journal of Preventive Veterinary Medicine**, v.11, p.185-200, 1991.
- JAPIASSÚ, L. B. Ciclos de poda e adubação nitrogenada em lavouras cafeeiras conduzidas no sistema “safra zero”. 2009.
- PEI, W.; LAN, Y.; XIWEN, L.; ZHIYAN, Z.; WANG, Z.; E WANG, Y. Sistema de sensor integrado para monitorar as condições de crescimento do arroz com base no sistema de veículo terrestre não tripulado. **Int. J. Agric. Biol. Eng.** 7, 75–81, 2014.



PEREIRA, S. P.; BALIZA, D. P.; SANTOS, M. O.; ALVES, J. D.; GUIMARÃES, R. J. Influência do espaçamento de cultivo em duas épocas de poda nos teores caulinares de carboidratos em cafeeiros. **Coffee Science**, v. 8, n. 4, p. 460-468, 2013.

PEREIRA, S. P.; GUIMARÃES, R. J.; BARTHOLO, G. F.; GUIMARÃES, P. T. G.; ALVES, J. D. Crescimento vegetativo e produção de cafeeiros (*Coffea arabica* L.) recepados em duas épocas, conduzidos em espaçamentos crescentes. **Ciência e agrotecnologia**, v. 31, p. 643-649, 2007.

QUEIROZ-VOLTAN, R. B.; CABRAL, L. P.; PARADELA FILHO, O.; FAZUOLI, L. C. Eficiência da poda em cafeeiros no controle da *Xylella fastidiosa*. **Bragantia**, v. 65, p. 433-440, 2006.

SANTOS, H.G.; JACOMINE, P.K.T.; ANJOS, L.H.; OLIVEIRA, V.A.; LUMBRERAS, J.F.; COELHO, M.R.; CUNHA, T.J.F. **Sistema Brasileiro de Classificação de Solos**. Brasília, Embrapa Solos, Brazil. 2018. p. 353.

WATSON, D. J. Estudos fisiológicos comparativos sobre o crescimento das culturas arvenses: I. Variação na taxa de assimilação líquida e área foliar entre espécies e variedades, e dentro e entre anos. **Annals of botany**, v. 11, n. 41, pág. 41-76, 1947 .

# SENSORIAMENTO REMOTO PARA A ESTIMATIVA DE PRODUTIVIDADE DE CAFÉ ARÁBICA EM LAVOURA MICROTERRACEADA

Jussara Oliveira Gervasio<sup>1</sup>; Gabriela Maria Amaral Vallim Costa<sup>1</sup>; Levi Fraga Pajehu<sup>2</sup>; Juliao Soares De Souza Lima<sup>3</sup>; Samuel De Assis Silva<sup>3</sup>

<sup>1</sup>Estudante de Agronomia, Graduando - Universidade Federal do Espírito Santo, UFES, Alegre - ES. gervasio.jussara@gmail.com / (28) 9 9977-8126; <sup>2</sup>Engenheiro Agrônomo, Doutorando - Universidade Federal do Espírito Santo, UFES, Alegre - ES; <sup>3</sup>Engenheiro Agrônomo, Professor - Departamento de Engenharia Rural, UFES, Alegre - ES

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** O objetivo do trabalho foi utilizar produtos de sensoriamento remoto orbital e regressão múltipla espacial para a predizer a produtividade de café arábica cultivado em área microterraceada. O estudo foi realizado em uma área microterraceada cultivada com café arábica. Os produtos de sensoriamento remoto foram gerados a partir de imagens orbitais obtidas pelo sensor MSI embarcado nos satélites Sentinel-2. Foi feita a extração dos valores de reflectância para cada ponto, e em seguida foram calculados os índices de vegetação: NDVI e NDRE. Os índices e à produtividade foram submetidos a análise estatística descritiva e geoestatística. Os índices de vegetação que foram significativamente correlacionados com a produtividade foram utilizados para predizer, por regressão múltipla, esta última. Apesar da correlação significativa os índices de vegetação não foram capazes de predizer a produtividade da lavoura cafeeira microterraceada.

**PALAVRAS-CHAVE:** Previsão de safra. ; Regressão múltipla espacial. ; Modelos matemáticos.

## REMOTE SENSING FOR THE ESTIMATION OF ARABICA COFFEE PRODUCTIVITY IN MICROTERRACE PLANTATIONS

**ABSTRACT:** The objective of this work was to use orbital remote sensing products and spatial multiple regression to predict the yield of arabica coffee grown in a microterrace area. The study was carried out in a microterrace area cultivated with Arabica coffee. The remote sensing products were generated from orbital images obtained by the MSI sensor onboard the Sentinel-2 satellites. The reflectance values were extracted for each point, and then the vegetation indices were calculated: NDVI and NDRE. The indices and productivity were submitted to descriptive and geostatistical statistical analysis. Vegetation indices that were significantly correlated with productivity were used to predict, by multiple regression, the latter. Despite the significant correlation, the vegetation indexes were not able to predict the productivity of the microterrace coffee crop.

**KEYWORDS:** Harvest forecast. ; Spatial multiple regression. ; Mathematical models.

**INTRODUÇÃO:** O Brasil está entre os principais produtores e exportadores de café no mercado mundial. Dentre os principais estados produtores de café do país, o Estado do Espírito Santo responde pela segunda maior produção ficando atrás apenas do Estado de Minas Gerais (CONAB, 2020). A maior parte das regiões produtoras de café arábica capixabas possuem topografia montanhosas, onde os tratamentos culturais são realizados por trabalhadores caminhando nas entrelinhas da lavoura, o que torna as operações onerosas e imprecisas, como alternativa para contornar os problemas da declividade das áreas, alguns agricultores têm recorrido ao microterraceamento como uma alternativa para permitir a adoção de implementos mecanizados para realização de tratamentos culturais.

Apesar seu grande valor socioeconômico para a população capixaba a produtividade do cafeeiro é muitas vezes incerta, pois segundo Ferraz et al. (2012). Tendo em vista o valor do café no mercado e os altos custos para a produção, prever a produtividade antes da colheita pode auxiliar na correção de problemas que dificultam o aumento da produção ainda durante o desenvolvimento dos grãos. Modelos para predição de produtividade ajudam no planejamento da logística de colheita, escoamento e armazenamento dos produtos agrícolas (ANDRADE et al., 2014). Considerando a necessidade de predição da produtividade do cafeeiro deve-se optar

por metodologias confiáveis e de baixo custo para realizar tal estimativa, podendo ser utilizadas imagens de satélites para realizá-la (CHEMURA, 2017). O sensoriamento remoto permite o monitoramento do estado fisiológico das plantas por meio da avaliação de fitomassa, teor de clorofila, estresses bióticos e abióticos, parâmetros importantes para a produção do café, tais aspectos podem ser observados por meio da energia refletida nas regiões espectrais do visível e do infravermelho próximo (MAHAJAN et al., 2014).

Há na literatura trabalhos que demonstram a importância da utilização de sensoriamento remoto no mapeamento do cafeeiro (BISPO et al., 2014; SOUZA et al., 2019), na detecção de estresses bióticos e abióticos por meio da utilização de índices vegetativos (MARIN et al., 2019), porém há ainda uma escassez de trabalhos que mostram a importância do sensoriamento remoto orbital para a predição da produtividade a partir de imagens geradas por satélites. Ante ao apresentado, esse trabalho é alicerçado na hipótese da possibilidade de utilizar sensoriamento remoto orbital para a predição, a partir de regressão múltipla espacial, de produtividade de lavouras cafeeiras, descrevendo os valores absolutos do rendimento dos cafés e a variabilidade espacial do fenômeno.

**MATERIAIS E MÉTODOS:** O estudo foi realizado, em uma lavoura comercial de café arábica localizada no município de Ibatiba, na Microrregião de Planejamento do Caparaó, no estado do Espírito Santo. O experimento foi conduzido em uma área inclinada onde foi realizado o nivelamento das entrelinhas de plantio de café através do que tem sido conhecido como microterraceamento. Para atendimento aos objetivos propostos o estudo foi executado em uma grade amostral irregular contendo 100 pontos amostrais que foi previamente montada na lavoura. Cada ponto amostral é composto por três plantas de café, onde foram realizadas as mensurações das variáveis de solo. Os pontos amostrais foram georreferenciados utilizando-se aparelho DGPS, com correção pós-processada, para a obtenção do posicionamento vertical e horizontal.

Foram utilizadas imagens mensais da área em estudo, orbitais obtidas pelo sensor MSI embarcado nos satélites Sentinel-2, porém consideradas apenas aquelas livres de interferência de nebulosidade. As imagens selecionadas foram processadas utilizando o software QGIS. As imagens após serem baixadas no formato .jp2, foram convertidas para o formato GeoTiff. Na sequência foram submetidas a processos de correção radiométrica ortorretificada em superfície-BOA e na conversão do número digital (ND) de cada pixel da imagem em valores físicos de reflectância (RT) dos alvos em superfície. Após o processamento inicial, os valores dos comprimentos de onda de cada banda espectral foram extraídos para cada ponto do grid amostral, utilizando o complemento Point Sampling Tools, o qual a partir de um arquivo vetorial de pontos (contendo as coordenadas geográficas de cada ponto), extrai valores de um arquivo matricial. Após a extração dos valores dos comprimentos de onda de cada banda espectral foram calculados os índices de vegetação. Nesse trabalho foram utilizados dois índices de vegetação capazes de descrever o comportamento do vigor vegetativo das plantas:

a) Índice de vegetação da diferença normalizada (NDVI): O NDVI é um índice de vegetação multiespectral e consiste na diferença normalizada entre as bandas da região do infravermelho próximo e do vermelho e é estimado pela equação:

$$NDVI = (NIR - R)/(NIR + R) \quad \text{Eq. (14)}$$

Em que: *NIR* = valores de reflectância na banda do infravermelho próximo, e; *R* = valores de reflectância na banda do vermelho (Red).

b) Índice de vegetação da diferença normalizada do RedEdge (NDRE): O NDRE é um índice de vegetação multiespectral e consiste na diferença normalizada entre as bandas da região do infravermelho próximo e do RedEdge e é estimado pela equação:

$$NDRE = (NIR - RedEdge)/(NIR + RedEdge) \quad \text{Eq. (15)}$$

Em que: *NIR* = valores de reflectância na banda do infravermelho próximo, e; *RedEdge* = valores de reflectância na banda do RedEdge.

A determinação da produtividade de cada ponto foi mensurada no momento em que cerca de 90% dos grãos estavam maduros, sendo a colheita feita por derriça manual. O volume de café colhido em cada ponto foi pesado para se obter os valores de massa de café úmido. Na sequência as amostras foram secas em estufa a 40°

C até atingir  $\pm 12\%$  de umidade, obtendo-se a massa de café seco. O café beneficiado foi determinado retirando-se a casca dos grãos secos, sendo esses submetidos à pesagem, obtendo-se a massa de café beneficiado. Para cada ponto amostral, os valores de café beneficiado foram convertidos em produtividade na unidade  $\text{Mg}\cdot\text{ha}^{-1}$ .

Os valores levantados para as variáveis em estudo foram submetidos à análise estatística descritiva e exploratória, por meio das medidas de posição e dispersão. A normalidade dos dados foi testada pelo teste de Shapiro-Wilk ( $p < 0,05$ ).

Em seguida os dados foram submetidos à análise geoestatística para verificar a existência e quantificar a dependência espacial, a partir do ajuste das funções teóricas aos modelos de variogramas experimentais com base na pressuposição de estacionaridade da hipótese intrínseca dos dados. Os variogramas experimentais foram estimados pela equação:

$$\gamma(h) = 1/(2N(h)) \sum_{i=1}^{N(h)} [Z(x_i) - Z(x_i + h)]^2 \quad \text{Eq. (16)}$$

Em que:  $N(h)$  é o número de pares experimentais de observações  $Z(x_i)$ ,  $Z(x_i+h)$ , separados por um vetor  $h$ .

No ajuste dos modelos teóricos aos variogramas experimentais, foram determinados os coeficientes efeito pepita, patamar, variância estrutural e alcance. Os modelos testados foram o esférico, exponencial, gaussiano e linear. A escolha seguiu o critério dos mínimos quadrados, optando-se pelo maior valor de coeficiente de determinação, menor soma de quadrado dos resíduos e maior valor do coeficiente de correlação obtido na validação cruzada. Comprovada a dependência espacial, foram construídos os mapas de distribuição espacial, utilizando-se a krigagem ordinária.

Com finalidade de testar a correlação espacial entre as variáveis (produtividade e índices de vegetação), foi realizada a análise de correlação linear de Pearson pixel a pixel ao nível de 5% de probabilidade, a partir dos dados da matriz de proximidade espacial

Para as relações produtividade x índices de vegetação (em diferentes períodos) que apresentaram correlação espacial significativa, os dados foram submetidos à análise de regressão múltipla espacial. Foi considerado como variável dependente os valores de produtividade e como variáveis independentes os valores dos índices de vegetação mensurados nos tempos “ $i$ ”, conforme equação:

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k \quad \text{Eq. (17)}$$

em que:  $Y$  = variável dependente;  $\beta_0$  = valores do intercepto;  $\beta_{i(i=1...k)}$  = valores dos coeficientes de regressão parciais, e;  $x_{i(i=1 a k)}$  = as variáveis independentes.


Para avaliar a acurácia dos modelos de regressão foi utilizado o coeficiente de desvios relativos. Essa análise permite descrever os desvios pontuais e médios entre os valores absolutos da produtividade predita em relação aos valores da produtividade mensurada. Para isso foram calculados os coeficientes de desvios relativos pontual (CDR<sub>i</sub>) e médio (CDR<sub>m</sub>), conforme as seguintes equações:

$$CDR_i = (Prod_{pred} - Prod_{calc}) / Prod_{calc} * 100 \quad \text{Eq. (18)}$$

$$CDR_m = \sum_{i=1}^n |CDR_i| / n \quad \text{Eq. (19)}$$

em que: CDR<sub>i</sub> = coeficiente de desvio relativo pontual (%); CDR<sub>m</sub> = coeficiente de desvio relativo médio absoluto (%);  $n$  = número de pontos amostrais;  $Prod_{pred}$  = valor pontual de produtividade predita;  $Prod_{calc}$  = valor pontual de produtividade mensurada em campo.

**RESULTADOS E DISCUSSÃO:** Ao analisarmos os estádios fenológicos do cafeeiro podemos compará-los com o comportamento da reflectância das plantas. Após a extração dos números digitais de cada banda das imagens mensais do Sentinel-2 foi construído um gráfico contendo a assinatura espectral média dos cafeeiros cultivados na área microterraceados estudada (Figura 1). A assinatura espectral consiste no modo como cada alvo na superfície terrestre absorve ou reflete a radiação (Figueredo, 2005). Não foi possível, neste trabalho, obter imagens dos primeiros meses da fase da granação dos grãos, pois havia interferência de nuvens nas imagens obtidas do satélite Sentinel-2 nos meses de janeiro e fevereiro.



**Figura 1** - Média da reflectância das bandas espectrais do Sentinel-2 em diferentes meses.

Analisando a imagem pode-se perceber a nitidamente discrepância da reflectância na banda do vermelho (B04) e na banda do infravermelho (B08) em todos os meses observados, sabe-se que plantas saudáveis tendem a absorver mais no vermelho e a refletir no infravermelho, resultando em índices de vegetação (NDVI) positivos (LILLESAND e KIEFER, 1999), esse comportamento foi verificado para todos os meses amostrados. A transição entre as bandas do vermelho e infravermelho são conhecidas como RedEdge (B05, B06, B07 e B08A), a reflectância nesses comprimentos de onda variam de acordo com a planta e o meio em que estas se encontram, estas bandas são mais sensíveis a oscilações na reflectância permitindo a detecção mais precoce de estresses (Seager et al., 2005). A relação entre o Infravermelho e as bandas RedEdge resulta no Índice de vegetação NDRE.

Em linhas gerais, os maiores valores de reflectância foram observados para os meses de Maio\_20, Mar\_20 e Abr\_20, principalmente para as bandas do RedEdge e do Infravermelho próximo, nestes meses as plantas apresentaram um maior vigor vegetativo, que pode ter sido causado pelas condições climáticas dos meses anteriores, variável que não foi mensurada neste estudo, ou ainda, pelo incremento de biomassa no cafeeiro devido à granação dos frutos (Rosa, 2007). No mês Dez\_19 os valores de reflectância foram os menores registrados, com exceção das bandas do visível onde os valores foram semelhantes aos demais períodos, isto pode ter sido ocasionado pelo carreamento de nutrientes das folhas para o início da formação dos grãos “chumbinhos”, reduzindo o vigor do dossel da lavoura (Camargo e Camargo, 2001), ou também por variáveis climáticas não mensuradas neste trabalho.

Na tabela 1 são apresentados os resultados das análises estatísticas descritivas para as variáveis produtividade, NDVI, NDRE1 e NDRE2 para os meses de setembro, outubro e dezembro do ano de 2019 e março, abril, maio, junho e julho do ano de 2020.

**Tabela 1** – Estatística descritiva para as variáveis produtividade e valores mensais de NDVI, NDRE1 e NDRE2.

Variáveis	Média	Mediana	Mínimo	Máximo	CV	Cs	Ck	W (p-valor)	r
Produtividade	109.09	112.12	43.25	167.37	27.53	0.16	-0.40	0.268	-

NDVI <sup>1</sup>	0.64	0.66	0.44	0.74	9.61	-0.92	0.75	0.000	0.30*
NDRE1 <sup>1</sup>	0.53	0.54	0.38	0.61	9.02	-0.70	0.53	0.009	0.33*
NDRE2 <sup>1</sup>	0.11	0.11	0.01	0.15	23.03	-1.28	2.59	0.000	0.19
NDVI <sup>2</sup>	0.53	0.54	0.35	0.65	11.86	-0.66	0.66	0.015	0.22*
NDRE1 <sup>2</sup>	0.47	0.47	0.36	0.58	9.43	-0.30	0.18	0.119	0.21*
NDRE2 <sup>2</sup>	0.13	0.14	0.08	0.17	11.18	-1.00	1.76	0.000	0.33*
NDVI <sup>3</sup>	0.50	0.50	0.29	0.65	13.01	-0.34	0.51	0.234	0.21*
NDRE1 <sup>3</sup>	0.37	0.36	0.28	0.47	12.33	0.47	-0.44	0.014	0.20
NDRE2 <sup>3</sup>	0.06	0.06	0.02	0.11	23.76	0.45	2.15	0.009	0.10
NDVI <sup>4</sup>	0.53	0.53	0.23	0.74	22.63	-0.44	-0.12	0.028	0.27*
NDRE1 <sup>4</sup>	0.53	0.57	0.21	0.65	21.17	-1.47	1.13	0.000	0.15
NDRE2 <sup>4</sup>	0.12	0.13	-0.02	0.23	36.97	-0.67	0.52	0.008	0.05
NDVI <sup>5</sup>	0.68	0.72	0.43	0.79	14.22	-0.98	-0.14	0.000	-0.02
NDRE1 <sup>5</sup>	0.61	0.62	0.41	0.73	10.67	-0.98	0.38	0.000	-0.02
NDRE2 <sup>5</sup>	0.13	0.13	0.03	0.26	25.24	-0.03	3.46	0.000	-0.02
NDVI <sup>6</sup>	0.76	0.77	0.65	0.81	5.02	-1.15	0.74	0.000	-0.09
NDRE1 <sup>6</sup>	0.58	0.58	0.50	0.66	5.73	-0.02	-0.08	0.961	-0.05
NDRE2 <sup>6</sup>	0.13	0.14	0.07	0.19	14.85	-0.29	1.38	0.094	-0.11
NDVI <sup>7</sup>	0.78	0.79	0.67	0.85	4.87	-0.74	0.28	0.002	-0.08
NDRE1 <sup>7</sup>	0.56	0.56	0.48	0.69	6.24	0.73	1.59	0.012	-0.05
NDRE2 <sup>7</sup>	0.16	0.16	0.12	0.24	13.36	1.00	1.99	0.000	-0.04
NDVI <sup>8</sup>	0.67	0.67	0.54	0.80	7.41	0.22	0.03	0.898	-0.02
NDRE1 <sup>8</sup>	0.48	0.47	0.38	0.66	11.58	0.86	0.74	0.001	-0.02
NDRE2 <sup>8</sup>	0.12	0.12	0.05	0.20	18.38	0.67	2.33	0.000	-0.13
NDVI <sup>9</sup>	0.57	0.55	0.41	0.77	14.04	0.48	-0.18	0.043	-0.02
NDRE1 <sup>9</sup>	0.46	0.44	0.34	0.67	15.99	1.06	0.72	0.000	-0.01
NDRE2 <sup>9</sup>	0.09	0.08	0.04	0.21	30.43	1.78	5.36	0.000	-0.11

<sup>1</sup>Setembro; <sup>2</sup>Outubro; <sup>3</sup>Novembro; <sup>4</sup>Dezembro; <sup>5</sup>Março; <sup>6</sup>Abril; <sup>7</sup>Maio; <sup>8</sup>Junho; <sup>9</sup>Julho; CV = coeficiente de variação; Cs = coeficiente de assimetria; Ck = coeficiente de curtose; W (p-valor) = teste de normalidade Shapiro-Wilk (p < 0,05); r = correlação linear de Pearson; \* correlação significativa a 5% de probabilidade.

A produtividade média da lavoura foi de 109,09 sacas.ha<sup>-1</sup>, valor superior à média de produtividade do estado do Espírito Santo que é de 30,9 sacas.ha<sup>-1</sup> na safra 2019/2020 (Conab, 2020). Ao analisarmos as médias dos índices vegetativos (IV) é possível verificar que os três índices apresentam uma variação temporal semelhante ao longo dos meses. Ainda podemos ver que as menores médias coincidem com os meses de outubro, novembro e dezembro, esse fato pode estar relacionado ao início de desenvolvimento dos chumbinhos, pois a planta passa a carrear nutrientes para a formação dos grãos (Camargo e Camargo, 2001). Ainda há a ocorrência de médias baixas nos meses junho e julho podem se relacionar à colheita e senescência das plantas, período no qual estas perdem vigor (Bernardes, et al., 2012). Já as maiores médias para índices são observados no mês de maio, fase maturação dos frutos, pode estar relacionada ao aumento de biomassa no cafeeiro por ocasião dos frutos, que aumenta o vigor das plantas (Rosa, 2007).

A produtividade média da lavoura foi de 109,09 sacas.ha<sup>-1</sup>, valor superior à média de produtividade do estado do Espírito Santo que é de 30,9 sacas.ha<sup>-1</sup> na safra 2019/2020 (Conab, 2020). Ao analisarmos as médias dos índices vegetativos (IV) é possível verificar que os três índices apresentam uma variação temporal semelhante ao longo dos meses. Ainda podemos ver que as menores médias coincidem com os meses de outubro, novembro e dezembro, esse fato pode estar relacionado ao início de desenvolvimento dos chumbinhos, pois a planta passa a carrear nutrientes para a formação dos grãos (Camargo e Camargo, 2001). Ainda há a ocorrência de médias baixas nos meses junho e julho podem se relacionar à colheita e senescência das plantas, período no qual estas perdem vigor (Bernardes, et al., 2012). Já as maiores médias para índices são observados no mês de maio, fase maturação dos frutos, pode estar relacionada ao aumento de biomassa no cafeeiro por ocasião dos frutos, que aumenta o vigor das plantas (Rosa, 2007).

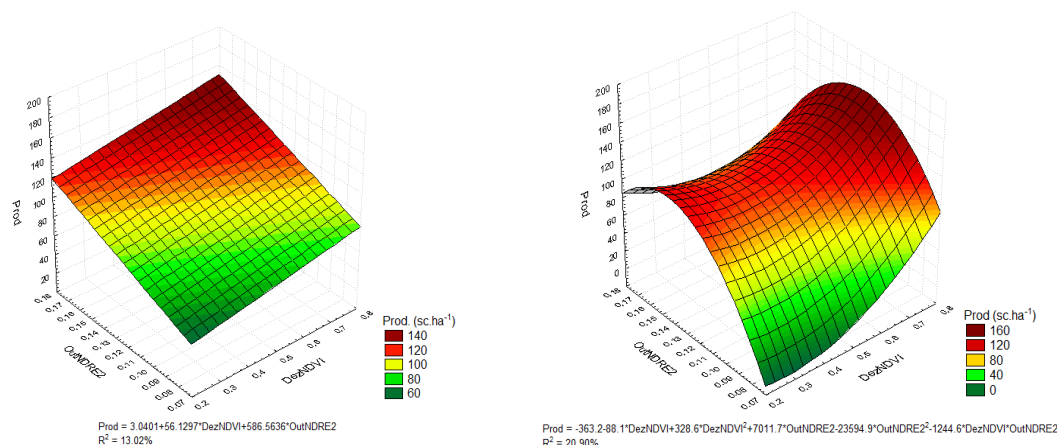
A mediana dos dados apresentou valores próximos ou iguais as médias, o que indica a tendência central dos dados não foi influenciada por outliers (Cambardella, 1994). O coeficientes de assimetria (Cs), curtose (Ck) e o teste de Shapiro-Wilk, estão relacionados a normalidade dos dados, ao analisarmos os resultados do teste de Shapiro-Wilk apenas a produtividade, o NDRE1<sup>2</sup>, NDRE1<sup>6</sup>, NDRE2<sup>6</sup> e o NDVI<sup>8</sup> apresentam normalidade na distribuição dos dados. É possível ainda visualizar este resultados por meio dos valores de Cs e Ck, já que a maioria está distante de zero. Para Cs, até o mês de maio os valores, são em sua maioria, negativos, ou seja, nestes meses houve maior concentração de valores mais altos dos índices (Artes, 2014), e o Ck indica o achatamento da curva de distribuição dos valores em relação à distribuição normal, na tabela acima pode-se ver que, exceto os índices que tiveram distribuição normal pelo teste de Shapiro-Wilk, os valores do coeficiente se distanciam de zero positivamente, ou seja, as curvas de distribuição dos dados apresentam caudas mais espessa (Vieira, 2018). Pimentel Gomes (2009) afirma que CV representa a precisão dos dados, e segundo a classificação proposta pelo autor classificar o CV da produtividade como alto, e médio para os índices de vegetação, com exceção do NDRE2 que apresenta maiores variações.

Por meio da correlação linear de Pearson pixel a pixel de 5% de probabilidade, foi verificado que há correlação significativa entre produtividade com o NDVI dos meses de setembro, outubro, dezembro e março, com o NDRE1 dos meses de setembro e outubro, e como o NDRE2 do mês de outubro. Por haver correlação linear significativa com a produtividade, estes índices de vegetação foram submetidos à análise de regressão múltipla espacial para a construção de um modelo para a predição de produtividade no cafeeiro arábica microterraceado.

Após a análise de regressão múltipla espacial apenas o NDVI do mês de dezembro e o NDRE2 do mês de outubro foram usadas na construção do modelo de predição. Para as variáveis estudadas foram construídos dois modelos, um como base na regressão linear e outro com base na regressão quadrática, conforme Figura 2. Ambos os modelos apresentaram R<sup>2</sup> classificados como baixos, pois ambos se encontram entre 0,10 e 0,29 (Cohen, 1998). Tal classificação sugere que os modelos não podem ser utilizados para prever a produtividade da safra de 2019/2020 desta lavoura cafeeira microterraçada na região de Ibatiba – Espírito Santo.

Por meio dos modelos obtidos a partir da regressão múltipla foi possível a construção dos gráficos apresentados na Figura 2. O gráfico à esquerda foi elaborado seguindo o modelo linear e o gráfico à direita seguindo o modelo quadrático. O NDVI do mês de dezembro varia entre 0.23 e 0.74 e o NDRE2 do mês de outubro variou 0.08 e 0.17.






**Figura 2** - Predição de produtividade do café arábica ( $sc.ha^{-1}$ ) em função dos valores do NDVI do mês de dezembro e do NDRE2 do mês de outubro, elaborado pelo modelo linear à esquerda, e pelo modelo quadrático à direita.

No primeiro gráfico, construído pelo modelo linear, pode ser verificado que o NDRE2 de outubro tem maior influência na produtividade, em relação ao NDVI do mês de dezembro, justificado pelo maior valor absoluto do coeficiente na equação do modelo. Vemos ainda neste gráfico que as maiores produtividades são atingidas com os maiores valores de NDVI, porém para que sejam obtidos tais valores o NDRE2 não necessariamente precisam ser os maiores. No segundo gráfico, construído pelo modelo quadrático, percebe-se que as maiores produtividades estão relacionadas a valores máximos de NDVI e a valores intermediários de NDRE2. Tendo vista tais observações, deve-se manejar a lavoura de forma que o NDVI tenha sempre os maiores valores possíveis, já que nos dois modelos os máximos valores de NDVI resultaram em maiores produtividades.


Na Figura 3 são apresentados os coeficientes de desvios relativos pontuais (CDRi) e médios (CDRm) para a relação entre a produtividade predita em relação a produtividade real mensurada.



**Figura 3** - Desvios relativos e médios entre a produtividade observada e predita por meio do modelo linear à esquerda, e pelo modelo quadrático à direita.

Ao observarmos o CDRm, é possível perceber que em ambos os modelos apresentam desvios médios absolutos muito semelhantes, o que indica que há semelhanças na produtividade estimada pelos modelos. Ao analisarmos o CDRi vemos que há uma dispersão de dados majoritariamente abaixo do CDRm, o que sugere que os modelos subestimam a produtividade a média foi influenciada por valores atípicos de produtividade. Tanto no ajuste do modelo linear, quanto no quadrático é visível uma maior concentração de desvios relativos negativos, o que pode indicar uma provável subestimação dos valores de produtividade pelos modelos em relação a produtividade real mensurada nestes pontos.

Após as análises estatísticas clássicas e a regressão múltipla espacial foram feitas as análises geoestatísticas. Na Figura 4 está representado o modelo para descrever variabilidade espacial do fenômeno estudado, o modelo de variograma mais adequado neste estudo é o esférico.

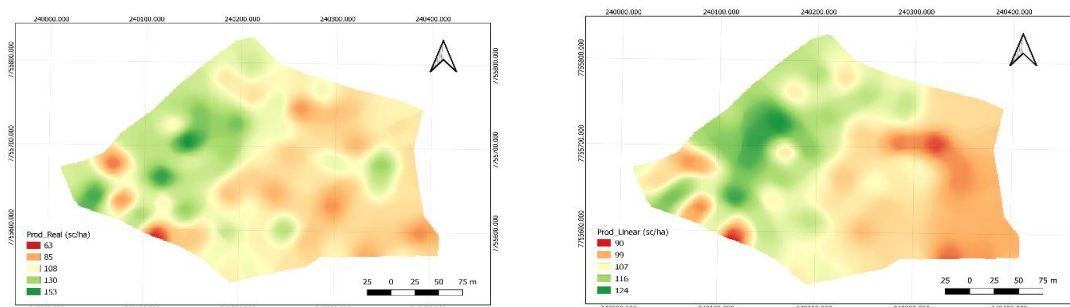



**Figura 4** – Variograma de modelo esférico da produtividade do cafeeiro.

A escolha do modelo esférico para variograma deu-se pelo coeficiente de determinação ( $R^2$ ). Este coeficiente consiste na relação entre a soma de quadrados devido ao modelo ajustado e a soma de quadrados total e quanto mais próximo de 100% estiver o valor de  $R^2$  melhor será o modelo ajustado (Guimarães, 2004). A descontinuidade existente na origem do variograma ( $C_0$ ), refere-se à possíveis erros amostrais ou a variações da produtividade que não podem ser explicados com base na escala de amostragem (Lima, 2016).

O patamar do variograma ( $C_0+C$ ) é o ponto a partir do qual as medições se tornam constantes e a produtividade passa a ter distribuição aleatória, distância em que o patamar é atingido é chama-se alcance. O alcance ( $a$ ) do variograma indica a distância a partir da qual as amostras não possuem mais dependência espacial e as observações são independentes uma das outras (Guimarães, 2004). Observou-se nesse estudo que a produtividade pode ser relacionada espacialmente em um raio de até 33 metros. O índice de dependência espacial (IDE) é uma medida que sintetiza diversas informações contidas no variograma, este índice abrange todos os parâmetros observados na dependência espacial, efeito pepita, contribuição, alcance e fator de modelo, sendo, portanto, uma medida completa de correlação espacial. O fator de modelo é importante já que dificilmente um fenômeno será observado com 100% de dependência espacial, mas em um grau específico conforme o modelo ajustado (Seidel e Oliveira, 2014). O IDE dos variogramas de produtividade mostra que esta pode ser classificada como forte dependência espacial (Seidel e Oliveira, 2016).

Na Figura 5 estão representados os mapas temáticos de produtividade da safra 2019/2020 da lavoura cafeeira microterraceada em estudo. Estão dispostos o mapa temático da produtividade real, da produtividade predita pelo modelo linear e a predita pelo modelo quadrático.





**Figura 5** – Mapas temáticos de produtividade ( $\text{sc.ha}^{-1}$ ) real, predita pelo modelo linear e predita pelo modelo quadrático.

O mapa da produtividade real foi construído por meio de interpolação após a definição do parâmetro do variograma. Os mapas de produtividade estimados pelos modelos de regressão foram aplicados aos mapas interpolados para os índices de vegetação. Ao analisarmos os mapas acima é possível visualizar as falhas nos modelos para a predição da produtividade, pois ambos os modelos diferem da produtividade real. Em ambos os mapas de predição da produtividade pode-se observar que os modelos superestimam os valores inferiores de produtividade e subestimam os maiores valores, isso pode ser explicado pela baixa correlação entre a produtividade real mensurada na safra de 2019/2020 e a produtividade predita pelos modelos linear e quadrático.

Apesar da baixa correlação entre a produtividade predita pelo modelo linear e a produtividade real mensurada na lavoura é possível verificar que a distribuição espacial onde da produtividade foi maior ou menor coincide em ambos os mapas, o que pode auxiliar no manejo do cafeeiro. De posse desses dados há a possibilidade de corrigir possíveis fatores que resultam em áreas em onde há uma menor predição produtividade, como estresses bióticos ou abióticos muito associados a produtividade (Mahajan et al., 2014).

**CONCLUSÃO:** Existe correlação significativa entre produtividade e o NDVI dos meses de setembro, outubro, dezembro e março, com o NDRE1 dos meses de setembro e outubro e como o NDRE2 do mês de outubro.

Apesar da correlação significativa, os modelos de predição de produtividade construídos a partir dos índices de vegetação não são efetivos para prever a produtividade de uma lavoura de café arábica cultivado em área microterraceada na safra 2019/2020.

#### **AGRADECIMENTOS:**

Agradeço a Fundação de Amparo à Pesquisa e Inovação do Espírito Santo (FAPES) pelo apoio financeiro através da bolsa concedida e, juntamente ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pelo apoio a pesquisa realizada.

#### **REFERÊNCIAS**

ALVES, E.L.; PEREIRA, F.A.C.; DALCHIAVON, F.C. Potencial econômico da utilização de microterraceamento em lavouras de café: um estudo de caso. **Revista iPecege**, v. 3, n. 1, p. 24-38, 2017.

ANDRADE, R.G.; SEDIYAMA, G.C.; SOARES, V.P.; GLERIANI, J.M.; MENEZES, S.J.M.C. Estimativa da produtividade da cana-de-açúcar utilizando sebal e imagens Landsat. **Revista Brasileira de Meteorologia**, v.29, n.3, 433 - 442, 2014.

- BERNARDES, T.; MOREIRA, M. A.; ADAMI, M.; GIAROLLA, A.; RUDORFF, B. F. T. Monitoring Biennial Bearing Effect on Coffee Yield Using MODIS Remote Sensing Imagery. **Remote Sensing**. V.4. 2012. BERNARDI, A.C.C.; CAMPANA, M.; BETTIOL, G. M.; OLIVEIRA, P. P. A.; INAMASU, R. Y.; RABELLO, L. M. Variabilidade de propriedades do solo, índices de vegetação e produtividade de pastagem sob manejo intensivo. **Embrapa Pecuária Sudeste**. São Carlos – SP. 2014.
- BISPO, R.C.; LAMPARELLI, R.A.C.; ROCHA, J.V. Using fraction images derived from Modis data for coffee crop mapping. **Engenharia Agrícola**, v.34, n.1, p.102-111. 2014.
- BLISKA, F. M. M.; VEGRO, C. L. R.; JÚNIOR, P. C. A.; MOURÃO, E. A. B; CARDOSO, C. H. S. Custos de produção de café nas principais regiões produtoras do Brasil. **Embrapa Café**. 2009.
- CÂMARA, G.; DAVIS, C.; MONTEIRO, A.M. Introdução à ciência da geoinformação. São José dos Campos, **INPE**, 2001. 324p
- CAMARGO, A. P.; CAMARGO, M. B. P. Definição e esquematização das fases fenológicas do cafeeiro arábica nas condições tropicais do Brasil. **Bragantia**. 2001.
- CHEMURA, A.; MUTANGA, O.; DUBE, T. Integrating age in the detection and mapping of incongruous patches in coffee (*Coffea arabica*) plantations using multi-temporal Landsat 8 NDVI anomalies. **International Journal of Applied Earth Observation and Geoinformation**, v.57, p. 01-13, 2017.
- COHEN, Jacob. 1998. Statistical Power Analysis for the Behavioral Sciences, 2º Edição. Mahwah, NJ: Lawrence Erlbaum Associates.
- CONAB (2020) Acompanhamento da safra brasileira: café. Disponível em:< <https://www.conab.gov.br/info-agro/safras/cafe/boletim-da-safra-de-cafe/item/14817-4-levantamento-de-cafe-safra-2020> >. Acesso em: 06 de set. de 2021.
- FERRAZ, G.A.E.S.; SILVA, F.M.; CARVALHO, L.C.C.; ALVES, M.C.; FRANCO, B.C. Variabilidade espacial e temporal do fósforo, potássio e da produtividade de uma lavoura cafeeira. **Engenharia Agrícola**, v.32, n.1, p.140-150, 2012.
- FIGUEIREDO, D. **Conceitos básicos de sensoriamento remoto**. São Paulo. 2005.
- GALEANO, E. V.; KROHLING, C. A. Viability Of Arabica Coffee In The State Of Espírito Santo Considering Manual And Semi-Mechanized Harvest. **Coffee Science** - v.14, n.2, 2019.
- GUIMARÃES, E. C. **Geoestatística básica e aplicada**. Uberlândia: Universidade Federal de Uberlândia, 2004.
- INCAPER. Cafeicultura - Café Arábica. Disponível em:< <https://incaper.es.gov.br/cafeicultura-arabica> > Acesso em: 07 de set. de 2021.
- LIMA, J. S. S; SILVA, S. A; OLIVEIRA, R. B; FONSECA, A. S. Estimativa da produtividade de café conilon utilizando técnicas de cokrigagem. **Revista Ceres**, v. 63, n. 1, p. 54-61, 2016.
- MAHAJAN, G.R.; SAHOO, R.N.; PANDEY, R.N.; GUPTA, V.K.; KUMAR, D. Using hyperspectral remote sensing techniques to monitor nitrogen, phosphorus, sulphur and potassium in wheat (*Triticum aestivum* L.). **Precision agriculture**, v. 15, p. 499-522, 2014.
- MAPA. Ministério da Agricultura, Pecuária e Abastecimento, 2018. Política Agrícola - Café no Brasil. Disponível em: < <https://www.gov.br/agricultura/pt-br/assuntos/politica-agricola/cafe/cafeicultura-brasileira> > . Acesso em: 07 de set. de 2021.
- MARIN, D.B.; ALVES, M.C.; POZZA, E.A.; GANDIA, R.M.; CORTEZ, M.L.J.; MATTIOTI, M.C. Sensoriamento remoto multiespectral na identificação e mapeamento das variáveis bióticas e abióticas do cafeeiro. **Revista Ceres**, v. 66, n.2, p. 142-153, 2019.

MATIELLO, J. B. **Procafé**: Tecnologia de microterraceamento em cafezais evolui bastante. Disponível em: < <https://www.noticiasagricolas.com.br/noticias/cafe/206273-procafe-tecnologia-de-micro-terraceamentoem-cafezais-evolui-bastante.html#.XXn6AtVKjIU> > Acesso em: 07 de set. de 2021.

PIMENTEL-GOMES, F. Curso de estatística experimental. 15. ed. Piracicaba: Fealq, 2009, 451p.

ROSA, V.G.C. Modelo agrometeorológico-espectral para monitoramento e estimativa da produtividade do café na região sul/sudoeste do estado de Minas Gerais. 142p. Dissertação (Mestrado em Sensoriamento Remoto), Instituto Nacional de Pesquisas Espaciais, São Jose dos Campos/SP, 2007.

SEAGER, S.; TURNER, E.L.; SCHAFER, J.; FORD, E.B. Vegetation's red edge: a possible spectroscopic biosignature of extraterrestrial plants. **Astrobiology**. N.03, V.5, 372–390. 2005.

SEIDEL, E. J; OLIVEIRA, M. S. Novo índice geoestatístico para a mensuração da dependência espacial. **Revista Brasileira Ciência Solo**, Viçosa, v. 38, n. 3, p. 699-705, 2014.

SEIDEL, E. J; OLIVEIRA, M. S. Proposta de generalização para modelos de semivariogramas exponencial e gaussiano. Semina: **Ciências Exatas e Tecnológicas**, v.34, p.125-132, 2016.

SOUZA, C.G.; ARANTES, T.B.; CARVALHO, L.M.T. DE; AGUIAR, P. Multitemporal variables for the mapping of coffee cultivation areas. **Pesquisa Agropecuária Brasileira**, v.54, e00017, 2019.

TAIPALE, E, Sentera. NDVI vs. NDRE: **What's the Difference?** (2018). Disponível em: <<https://sentera.com/insights/ndvi-vs-ndre-whats-the-difference/>> Acesso em: 07 de set. de 2021.

VOLSI, B.; TELLES, T. S.; CALDARELLI, C. E.; CAMARA, M. R. G.; The dynamics of coffee production in Brazil. *Plos One*. 2019.

# CALIBRAÇÃO DE MEDIDOR PORTÁTIL PARA ESTIMATIVA DE TEOR FOLIAR DE N EM FUNÇÃO DE ZONAS DE VIGOR VEGETATIVO DE VIDEIRAS FERTIRRIGADAS

Luis Henrique Bassoi<sup>1</sup>; Thassio Monteiro Menezes da Silva<sup>2</sup>; Bruno Ricardo Silva Costa<sup>3</sup>; Henrique Oldoni<sup>4</sup>; Milene Corso Mitsuyuki<sup>5</sup>

<sup>1</sup>Engenheiro Agrônomo, Pesquisador - Embrapa Instrumentação, Rua XV de Novembro, 1452 CEP 13561-206 São Carlos - SP. luis.bassoi@embrapa.br / (16) 9 8206-4653; <sup>2</sup>Engenheiro Agrônomo, Doutorando - FCA UNESP Depto de Engenharia Rual e Socioeconomia, Av. Universitária, 3780 CEP 18610-034 Botucatu-SP; <sup>3</sup>Engenheiro Agrônomo, Doutor - FCA UNESP Depto de Engenharia Rual e Socioeconomia, Av. Universitária, 3780 CEP 18610-034 Botucatu-SP; <sup>4</sup>Engenheiro Arícola, Doutor - FCA UNESP Depto de Engenharia Rual e Socioeconomia, Av. Universitária, 3780 CEP 18610-034 Botucatu-SP; <sup>5</sup>Estatística, Analista - Embrapa Instrumentação, Rua XV de Novembro, 1452 CEP 13561-206 São Carlos - SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** O monitoramento do teor foliar de nitrogênio pode auxiliar no manejo nutricional de uma cultura. O presente trabalho teve como objetivo propor um procedimento de fácil utilização do clorofilômetro portátil no contexto da viticultura de precisão. O estudo foi desenvolvido em um vinhedo com a ‘Chardonnay’ sobre o porta-enxerto ‘Paulsen 1103’ e fertirrigado por gotejamento. Leituras com o medidor portátil de clorofila foram realizadas em 40 plantas em duas zonas de vigor vegetativo da videira e em 4 datas de amostragem de folhas ao longo do ciclo de produção da cultura em 2019. Posteriormente, foram determinados em laboratório os teores de nitrogênio foliar para relacioná-los com os índices relativos de clorofila por meio de equações de estimativa generalizada. A função desenvolvida para o teor foliar de N apresenta erro de predição considerável, porém capaz de fornecer uma boa estimativa.

**PALAVRAS-CHAVE:** Videira para vinho; zona homogênea; viticultura de precisão

## CALIBRATION OF PORTABLE METER TO ESTIMATE N LEAF CONTENT AS A FUNCTION OF VEGETATIVE VIGOR ZONES OF FERTIRRIGATED VINES

**ABSTRACT:** The monitoring of the leaf N content is helpful to the crop nutritional management. The present work aimed to propose an easy-to-use procedure for the hand-held chlorophyll meter in the context of precision viticulture. The study was carried out in a vineyard with ‘Chardonnay’ grafted onto ‘Paulsen 1103’ rootstock and fertigated by a drip irrigation system. Readings with the hand-held meter were performed on 40 plants from two grapevine’s vegetative vigor and on 4 leaf sampling dates throughout the 2019 growing season. Subsequently, the leaf nitrogen contents were determined in laboratory to relate them to the relative chlorophyll indices through generalized estimation equations. The function developed for the leaf N content presents considerable prediction error, but capable of providing a good estimate.

**KEYWORDS:** Wine grapevine; homogeneous zone; precision viticulture

**INTRODUÇÃO:** O nitrogênio é um elemento vital às plantas por ser parte constituinte de inúmeros compostos orgânicos como clorofilas, proteínas, ácidos nucléicos, enzimas, coenzimas e citocromos (O’Brien et al., 2016). Em algumas culturas, o teor de clorofila nas folhas se correlaciona positivamente com a concentração foliar de nitrogênio (N), correspondendo a 70% do N (nitrogênio) contido nos cloroplastos ao participarem da síntese e da estrutura da clorofila (Wood *et al.*, 1993). Os modelos que descrevem a relação entre as leituras dos equipamentos portáteis variam com a cultura e requerem calibração independente (Uddling *et al.*, 2007). O clorofilômetro portátil possibilita estimar os conteúdos de N presente nas folhas através do ajuste de funções de regressão, e se tornar uma ferramenta de gestão agrícola, com ênfase na viticultura de precisão, por meio do monitoramento da variabilidade espacial e temporal desse atributo da planta. Assim, o presente trabalho teve como objetivo propor um procedimento para a calibração do clorofilômetro levando-se em conta as zonas de vigor vegetativo da videira em um vinhedo fertirrigado por gotejamento.

**MATERIAIS E MÉTODOS:** O estudo foi desenvolvido no município de Espírito Santo do Pinhal, São Paulo, em um vinhedo com a *cv.* Chardonnay enxertada sobre o porta-enxerto Paulsen 1103 subdividido em duas áreas contíguas que juntas somam 1,1 ha, implantado em 2008 e fertirrigado por um sistema de irrigação localizada (gotejamento). As aplicações de nitrato de amônio via irrigação ocorreram aos, 2, 3, 11 e 23 dias após a poda (DAP) com doses equivalentes a 12,6 kg ha<sup>-1</sup>, 36,0 kg ha<sup>-1</sup>, 36,0 kg ha<sup>-1</sup> e 36,0 kg ha<sup>-1</sup>, nessa ordem. O solo do vinhedo foi classificado como Cambissolo Háplico Tb, A moderado, e Neossolo Regolítico, A húmico, ambos eutróficos típicos, de textura argilosa, com cascalho, apresentando na área 1 um complexo e na área 2 uma associação dos mesmos (Oldoni *et al.*, 2021). Com base na distribuição espacial do NDVI da área evidenciada nos ciclos de produção de 2017 e 2018 por Oldoni *et al.* (2021), foi possível relacionar nas ocasiões o NDVI com o vigor vegetativo das videiras. Desta maneira, as zonas de NDVI orientaram na escolha dos locais para a coleta de dados no ciclo de produção de 2019 (FIGURA 1), que teve a sua poda em 7 de janeiro e a colheita em 17 de maio (ciclo de 130 dias), em um sistema de produção de uvas para colheita no inverno, utilizando o manejo da dupla-poda da videira.

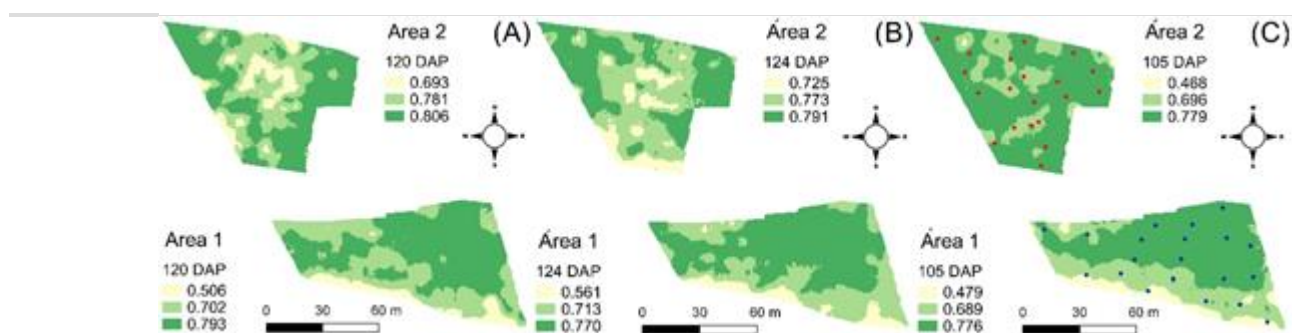


FIGURA 1. Distribuição espacial do índice de vegetação por diferença normalizada (NDVI) referente aos anos de 2017(A), 2018(B) e 2019(C).

As leituras com o medidor portátil de clorofila foram realizadas em 40 plantas (FIGURA 1C) por data de coleta com os estádios fenológicos ocorrendo em 7 de fevereiro (brotação), 22 de fevereiro (chumbinho), 21 de março (ervilha) e 22 de abril (maturação), e correspondentes a 31, 46, 73 e 105 dias após a poda (DAP). Em cada planta foram selecionadas duas folhas totalmente expandidas, sem o indício do ataque de pragas ou de doenças, com a realização das medidas sendo feitas em dois pontos na face adaxial de cada folha. Entre as 40 plantas amostradas por data (160 no total), os teores de nitrogênio foram determinados em 10 plantas por data (40 no total). As plantas foram selecionadas baseado nos índices relativos de clorofila (IC) fornecidos pelo clorofilômetro onde as 5 maiores e as 5 menores de cada data foram processadas para a determinação do teor foliar de nitrogênio total (NF), pelo analisador elementar modelo Perkin-Elmer CHN 2400, conforme Merlini *et al.* (2017). Os IC foram relacionados com os teores de N por meio do método das equações de estimativa generalizada (Zeger e Liang, 1986; Liang e Zeger, 1986) para estimar parâmetros de regressão especialmente quando os dados são autocorrelacionados. Os modelos de calibração de IC em função de NF foram desenvolvidos a partir dos dados obtidos na Área 1 (70% dos dados), sendo sua validação realizada com dados pertencentes à Área 2 (30% dos dados). A classificação do modelo melhor ajustado foi feita com base no RMSE (raiz do erro quadrático médio). O *software* utilizado nas análises foi o R versão 4.03 (R CORE TEAM, 2021) e o pacote utilizado foi “geepack” desenvolvido por Højsgaard, Halekoh e Yan (2006).

**RESULTADOS E DISCUSSÃO:** O modelo descrito na TABELA 1 foi o que apresentou o melhor resultado para a predição do teor de nitrogênio foliar em videiras ‘Chardonnay’ em função dos índices relativos de clorofila *a* e *b* obtidos pelo clorofilômetro.

TABELA 1. Modelo de predição do teor de nitrogênio foliar ajustado em função dos índices relativos de clorofila *a* e *b* obtidos pelo clorofilômetro.

Modelo	R <sup>2</sup>	RMSEP
$N_{\text{foliar}} = 59,355 - 4,1333 * (\text{clorofila } a) + 0,0686 * (\text{clorofila } a)^2 + 6,1294 * (\text{clorofila } b) - 0,3079 * (\text{clorofila } b)^2$	0,26	3,39

R<sup>2</sup>: coeficiente de determinação; RMSEP: raiz do erro quadrático médio da estimativa

Os resultados contidos na TABELA 2 representam a análise de variância do modelo de estimação generalizada desenvolvido para a calibração do clorofilômetro em função do teor de nitrogênio foliar presente nas videiras ‘Chardonnay’. O comportamento dos dados foi melhor representado por uma função quadrática ascendente.

TABELA 2. Modelo de predição do teor de nitrogênio foliar ajustado em função dos índices relativos de clorofila *a* e *b* obtidos pelo clorofilômetro.

FV	GL	$\chi^2$	p-valor
Clorofila <i>a</i>	1	27,26	<0,001
(Clorofila <i>a</i> ) <sup>2</sup>	1	0,09	0,77
Clorofila <i>b</i>	1	0,09	0,77
(Clorofila <i>b</i> ) <sup>2</sup>	1	16,35	<0,001

FV: fonte de variação; GL: grau de liberdade;  $\chi^2$ : qui-quadrado

Os dados apresentados na FIGURA 1 são referentes ao modelo de predição do teor de nitrogênio foliar a partir dos índices relativos de clorofila *a* e *b* (medidas fornecidas pelo equipamento). Com base nos resultados para calibração e validação do modelo, os coeficientes de determinação foram de 0,67 e 0,26 o que significa que o modelo quando validado é capaz de explicar apenas 26% dos dados. Taskos *et al.* (2015) encontraram comportamentos semelhantes para o SPAD-502 com os coeficientes de determinação da calibração variando entre 0,44 a 0,74 e 0,15 a 0,52, respectivamente, para videiras ‘Cabernet Sauvignon’ e ‘Xinomavro’. Vale ressaltar que os modelos apresentados por Taskos *et al.* (2015) não foram validados como no presente estudo.







FIGURA 1. Modelos de calibração e validação para a predição do teor de nitrogênio foliar em videiras ‘Chardonnay’ a partir do índice relativo de clorofila total obtido pelo clorofilômetro.

Já os valores obtidos para o RMSEC e o RMSEP foram os melhores resultados para a calibração e validação do modelo de predição do clorofilômetro, correspondendo a 1,49 e 3,39 respectivamente. A diferença existente entre os valores do RMSEC e RMSEP demonstram a necessidade da validação dos modelos, uma vez que somente a calibração não é o suficiente para atestar a precisão e a acurácia dos mesmos. Quanto ao emprego prático dos modelos obtidos, é possível afirmar a existência de certo grau de limitação. A depender da amplitude de suficiência nutricional adotada, o modelo pode apresentar um erro (RMSEP) maior que a diferença entre os limites máximo e mínimo. Mesmo diante este cenário, o modelo pode ser empregado desde que considerado o seu erro, podendo proporcionar aos usuários uma boa estimativa do estado nutricional do vinhedo. Para Taskos *et al.* (2015), a alta complexidade existente nas relações entre o nitrogênio e ambiente impossibilitam a sua compreensão por meio de um único modelo matemático, necessitando assim, de modelagens periódicas.

**CONCLUSÃO:** A calibração e validação do clorofilômetro para estimativa de teores de nitrogênio foliar na videira permite afirmar que a função desenvolvida apresenta erro de predição, porém mesmo diante das suas limitações é capaz de fornecer ao usuário uma boa estimativa do estado nutricional, principalmente quando operado em maiores amplitudes de suficiência nutricional.

#### **AGRADECIMENTOS:**

À Vinícola Guaspari (Espírito Santo do Pinhal - SP), pela cessão do vinhedo para realização do trabalho em parceria. Ao CNPq e à CAPES, pela concessão de bolsas de estudos, respectivamente, ao segundo e terceiro autores e ao quarto autor. À Rede de Agricultura de Precisão da Embrapa, pelo suporte técnico.

#### **REFERÊNCIAS**

HØJSGAARD, S.; HALEKOH, U; YAN, J.; 2006: The R Package geepack for Generalized Estimating Equations. *J. Stat. Softw.* **15**, 1-11.

LIANG, K. Y.; ZEGER, S. L. Longitudinal data analysis using generalized linear models. *Biometrika*, v.73: 13-22, 1986.

MERLINI, C.; BARRA G. M. O.; CUNHA, M. D. P. P.; RAMÔA, S. D. A. S.; SOARES, B. G.; PEGORETTI, A. Compósitos eletricamente condutivos de poliuretano derivados do óleo de mamona com fibras de palma de pêssego revestidas com polipirrol. *Compósitos de polímeros*, v.38, n.10, p. 2146-2155, 2017.

O'BRIEN, J. A.; VEJA, A.; BOUGUYON, E.; KROUK, G.; GOJON, A.; CORUZZI, G.; GUTIÉRREZ, R. A.; 2016: Nitrate Transport, Sensing, and Responses in Plants. *Mol Plant* **9**, 837-856. DOI: <http://dx.doi.org/10.1016/j.molp.2016.05.004>

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, n.4, e20190243, 2021. DOI: 10.1590/1678-992x-2019-0243.

R CORE TEAM; 2021: R: A language and environment for statistical computing. R Foundation for Statistical Computing.

SHAH, S. H.; HOUBORG, R.; MC CABE, M. F.; 2017: Response of chlorophyll, carotenoid and SPAD-502 measurement to salinity and nutrient stress in wheat (*Triticum aestivum L.*). *Agron J* **7**, 61-81. DOI: <https://dx.doi.org/10.3390/agronomy7030061>

TASKOS, D. G.; KOUNDOURAS, S.; STAMATIADIS, S.; ZIOZIOU, E.; NIKOLAOU, N.; KARAKIOULAKIS, K.; THEODOROU, N. Using active canopy sensors and chlorophyll meters to estimate grapevine nitrogen status and productivity. **Precision agriculture**, v. 16, n. 1, p. 77-98, 2015. DOI: 10.1007/s11119-014-9363-8.

UDDLING, J.; GELANG-ALFREDSSON, J.; PIIKKI, K.; PLEUEL, H. Evaluating the relationship between leaf chlorophyll concentration and SPAD-502 chlorophyll meter readings. **Journal Photosynthesis Research**, Netherlands, v. 91, n. 1, p. 37-46, 2007. DOI: 10.1007/s11120-006-9077-5

WOOD, C. W.; REEVES, D. W.; HIMELRICK, D. J. Relationships between chlorophyll meter readings and leaf chlorophyll concentration, N status, and crop yield: a review. **Proceedings Agronomy Society of New Zealand**, v. 23, p. 1-9, 1993.

ZEGER, S. L.; LIANG, K. Y. Longitudinal data analysis for discrete and continuous outcomes. **Biometrics**, v. 42, p. 121-130, 1986.

# PODA MECANIZADA NA MACIEIRA E SEUS EFEITOS NO ÍNDICE DE VEGETAÇÃO POR DIFERENÇA NORMALIZADA (NDVI)

CHRISTIAN BREDEMEIER<sup>1</sup>; VICTÓRIA REIS BORTOLUZ<sup>2</sup>; BRUNO TADASHI CHIBA DA SILVA<sup>3</sup>; NATÁLIA DE VAZ SCHAEFFER<sup>4</sup>; ANNA ELISA PETERSEN GATELLI<sup>5</sup>

<sup>1</sup>Eng. Agrônomo, Professor - Departamento de Plantas de Lavoura, Universidade Federal do Rio Grande do Sul (UFRGS). bredemeier@ufrgs.br / (51) 9 9963-1428; <sup>2</sup>Eng. Agrônomo, Aluno do PPG Fitotecnia - Departamento de Plantas de Lavoura, Universidade Federal do Rio Grande do Sul (UFRGS); <sup>3</sup>Eng. Agrônomo, Aluno do PPG Fitotecnia - Departamento de Plantas de Lavoura, Universidade Federal do Rio Grande do Sul (UFRGS); <sup>4</sup>Estudante de graduação, Aluno do Curso de Agronomia - Departamento de Plantas de Lavoura, Universidade Federal do Rio Grande do Sul (UFRGS); <sup>5</sup>Estudante de graduação, Aluno do Curso de Agronomia - Departamento de Plantas de Lavoura, Universidade Federal do Rio Grande do Sul (UFRGS)

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** A poda é um dos principais tratos culturais na cultura da maçã (*Malus domestica*), sendo responsável por potencializar e regular seu rendimento ao longo das safras. Nesse estudo, buscou-se avaliar o efeito dos diferentes sistemas de poda no comportamento espectral da macieira durante o ciclo da cultura, por meio do NDVI em duas alturas de leitura (1,20 e 2,00 m). A partir das avaliações, pode-se observar que não houve interação entre os fatores tratamentos e altura de leitura. A resposta do NDVI nas diferentes alturas apresentou diferença estatística, onde os maiores valores encontrados foram obtidos na leitura de 1,20m.

**PALAVRAS-CHAVE:** *Malus domestica*; Poda mecanizada; Índice de vegetação

## MECHANIZED PRUNING IN THE APPLE TREE AND EFFECTS ON THE NORMALIZED DIFFERENCE VEGETATION INDEX (NDVI)

**ABSTRACT:** Pruning is one of the main cultural practices in apple (*Malus domestica*), being responsible for enhancing and regulating its yield throughout the seasons. In this study, we sought to evaluate the effect of different pruning systems on the spectral behavior of apple trees during the crop cycle, using NDVI at two reading heights (1.20 and 2.00 m). From the evaluations, it can be observed that there was no interaction between the treatment factors and reading height. The NDVI response at different heights showed a statistical difference, where the highest values found were obtained in the reading of 1.20 m.

**KEYWORDS:** *Malus domestica*; Mechanized pruning; Vegetation index

**INTRODUÇÃO:** A produção mundial de maçãs na safra de 2018, segundo a FAO, foi de aproximadamente 86,1 milhões de toneladas, sendo o Brasil o 13º maior produtor, correspondendo a 1,39% da produção mundial. Denominada como *Malus x Domestica* Borkh. (KORBAN; SKIRVIN, 1984) ou *M. domestica* Borkh. (PHIPPS et al., 1990), a macieira é supostamente um híbrido complexo, pertencente à família *Rosaceae*, ordem *Rosales* e subfamília *Pomoideae*.

A cultura da maçã é uma das primeiras culturas que implantou o sistema de produção integrada, buscando utilizar tecnologias de controle através do monitoramento de todas as etapas produtivas. Apesar disso, a maioria das práticas de manejo atualmente são realizadas de forma manual, demandando elevada disponibilidade de mão-de-obra e, em consequência, elevação do custo de produção. Uma das principais práticas de manejo demandadas pela macieira é a poda, a qual busca um equilíbrio entre o crescimento vegetativo e a produção de frutos (RUFATO, 2016). Desta forma, a poda confere às plantas um maior potencial produtivo e uma maior regularidade produtiva ao longo das safras agrícolas.

A Agricultura de Precisão (AP) possui inúmeras ferramentas tecnológica e, dentre estas, a avaliação do “Índice de Vegetação por Diferença Normalizada (NDVI)” apresenta grande potencial de uso durante as etapas do

ciclo produtivo na agricultura. A utilização do NDVI na cultura da macieira possibilita um acompanhamento *in loco* e em tempo real da variabilidade espacial, podendo indicar deficiência nutricional e outros tipos de estresses, além da produção de biomassa vegetal, possibilitando o entendimento da dinâmica de crescimento vegetativo da cultura (AMARAL; MOLIN, 2011; RAPAPORT et al., 2014). Entretanto, o uso do NDVI relacionado ao manejo da poda da macieira ainda é incipiente.

Dessa forma, o objetivo deste trabalho foi avaliar o comportamento espectral do Índice de Vegetação por Diferença Normalizada (NDVI) da macieira durante um ciclo de produção sob diferentes sistemas de poda.

**MATERIAIS E MÉTODOS:** O experimento foi realizado na safra agrícola de 2020/2021 e conduzido em uma quadra de um pomar comercial pertencente à empresa Campi Frutas Ltda., localizada no município de Vacaria (Rio Grande do Sul, Brasil). O clima e tipo do solo do local de estudo é classificado como temperado úmido com verões amenos (Cbf), segundo a classificação de Koppen, e Latossolo Bruno Aluminoférrico típico (LBaf), respectivamente. A quadra avaliada possui 2,35 hectares e densidade populacional de 5.000 plantas/ha. A idade do pomar é de 15 anos e a cultivar avaliada foi a ‘Gala’, sob o porta-enxerto M9.

O delineamento experimental utilizado foi de blocos ao acaso, totalizando 20 unidades experimentais e com quatro repetições. Os tratamentos avaliados foram: testemunha (sem poda), poda padrão da unidade produtiva (poda padrão), poda mecanizada de outono, poda mecanizada de verão e poda mecanizada de outono e verão. Cada unidade amostral foi composta por três linhas de cultivo, com 13 metros de comprimento, e a área avaliada foi a área central da linha central da unidade amostral. A poda mecanizada foi realizada por implementos podadores denominados “HLC-3” e “HLC-5”, da empresa Hidrautec (Figura 1), os quais foram devidamente regulados visando podar a parte superior e a parte lateral, conforme a estatura do dossel vegetal e nos períodos indicados nos tratamentos.



FIGURA 1. Máquina utilizada para a poda. **Pruning machine.**

As avaliações do NDVI foram realizadas em duas faixas de altura, sendo a 1,20 e a 2,00 metros. Isso se deve ao fato das plantas de macieira apresentarem estrutura trapezoidal e uma altura de aproximadamente 3,80 metros, possibilitando, assim, uma média mais representativa da amostra. O equipamento utilizado foi o sensor Greenseeker® o qual estima valores de NDVI usando a relação  $(\rho_{ivp} - \rho_v)/(\rho_{ivp} + \rho_v)$ , onde  $\rho_{ivp}$  e  $\rho_v$  se referem à reflectância do infravermelho próximo e vermelho, respectivamente. O NDVI foi avaliado

mensalmente durante o ciclo de desenvolvimento da cultura da macieira, com avaliações a cada 30 dias após período de dormência. A nutrição das plantas e o controle de pragas e doenças foi realizado pelo produtor seguindo as recomendações agrônômicas e as boas práticas de manejo preconizadas para a cultura.

Os dados foram previamente analisados quanto à presença de outliers e o diagnóstico da normalidade. Posteriormente, os dados foram submetidos à análise de variância pelo teste F ( $p \leq 0,05$ ), sendo que, em caso de significância, as médias dos diferentes tratamentos foram comparadas pelo teste de Tukey ( $p \leq 0,05$ ). As análises foram realizadas no software RStudio.

**RESULTADOS E DISCUSSÃO:** Os tratamentos possibilitaram a identificação, durante o ciclo de desenvolvimento, de diferenças significativas no valor do NDVI avaliado nos meses de dezembro e fevereiro para a altura de avaliação de 1,20 m (Figura 2A). Já para a altura de 2,00 m, houve diferença significativa no mês de novembro (Figura 2B). Isso reflete as épocas de maior demanda nutricional e de fotoassimilados pela planta, sendo os estádios de desenvolvimento e maturação dos frutos.

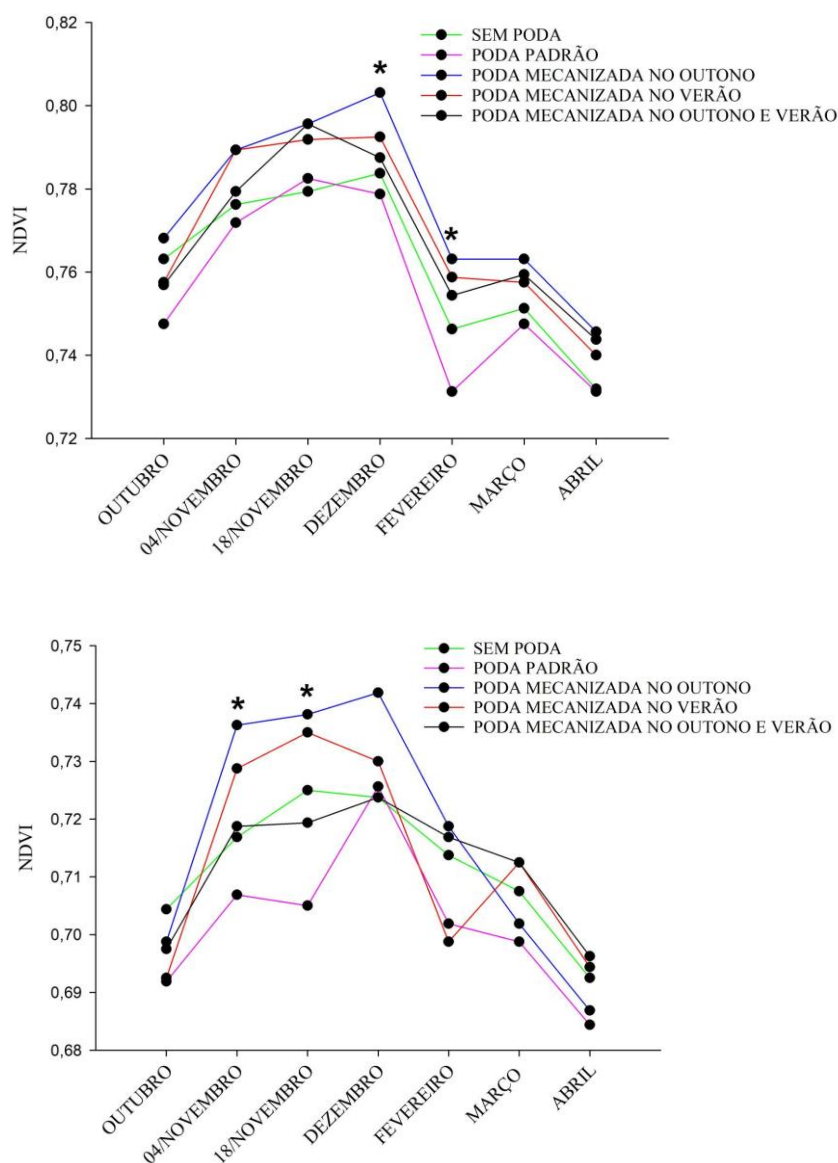
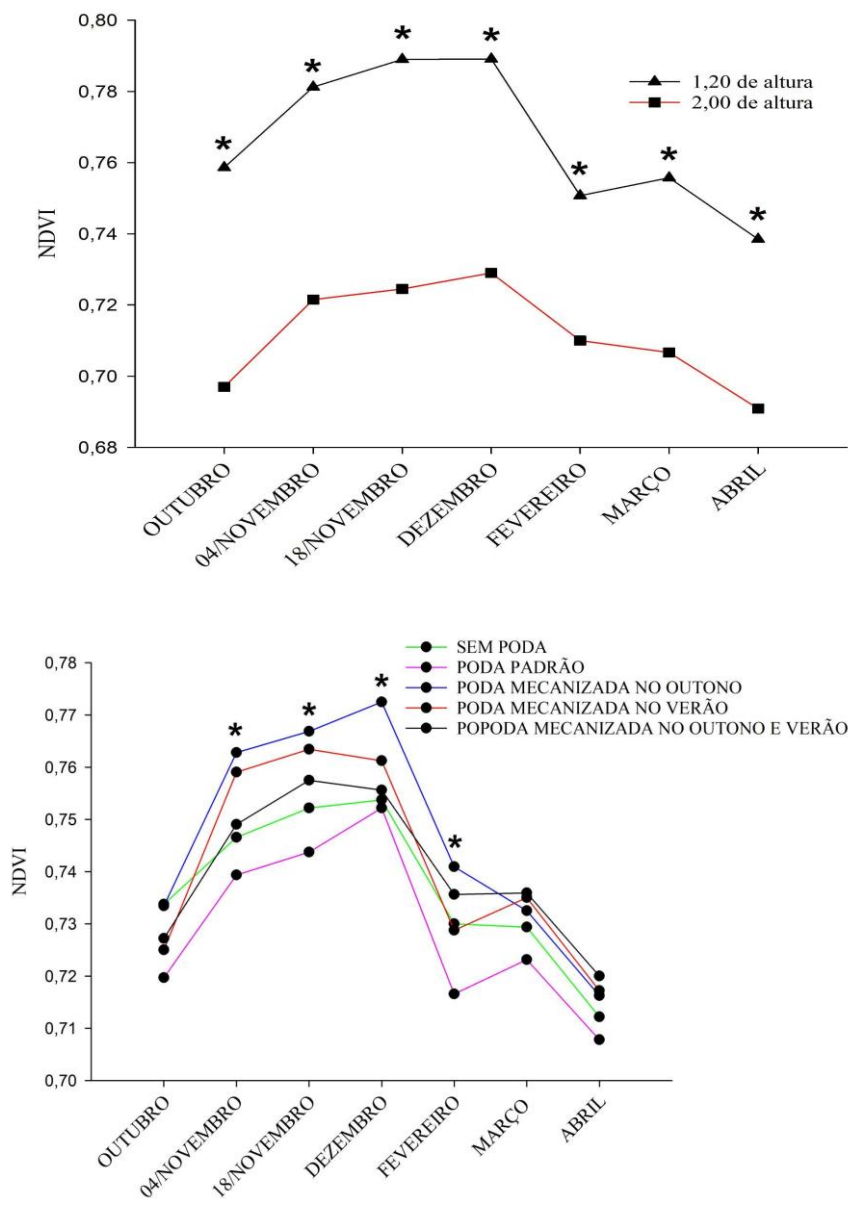


FIGURA 2. Resposta do NDVI ao longo do ciclo da cultivar 'Gala' avaliada nas alturas de 1,20m (A) e 2,00m (B), em função de diferentes formas de poda. **NDVI response throughout the cycle of cultivar 'Gala' at heights of 1.20m (A) and 2.00m (B) in different pruning methods.**

Ao se comparar a resposta do NDVI às diferentes alturas, pode-se observar que não houve diferença estatística entre os tratamentos. Assim, pode-se avaliar a média obtida de todos os tratamentos em relação às diferentes alturas. Independentemente da data de avaliação, o NDVI na altura de 2,00 metros foi inferior estatisticamente ao NDVI observado na altura de 1,20 metro (Figura 3A). Tal resultado reflete o fato da estrutura da planta ser em forma trapezoidal, a qual apresenta maior acúmulo de biomassa no estrato inferior e, assim, maior valor do NDVI. Quando comparou-se a resposta do NDVI ao longo do ciclo aos diferentes tratamentos, os meses de novembro, dezembro e fevereiro diferiram estatisticamente dos demais (Figura 3B).



(A)

FIGURA 3. Resposta do NDVI da cultivar 'Gala' ao longo do ciclo, em função das alturas de avaliação de 1,20 e 2,00 metros (A) e em função dos tratamentos de poda (B). **NDVI response of the 'Gala' cultivar throughout the cycle: as a function of heights 1.20 and 2.00 meters (A) and as a function of treatments (B).**

Outra informação importante que pode ser analisada com base nos resultados apresentados é o comportamento espectral ou a resposta do NDVI ao longo do ciclo de desenvolvimento da cultura. Pode-se definir, com base nas observações de campo e nos valores de NDVI, que o mês de outubro é o período em que a cultura está em plena brotação e com bom desenvolvimento foliar. Já nos meses de novembro e dezembro, em que as plantas estão no período de frutificação, observa-se que o NDVI fica próximo à faixa de saturação. Já nos meses de fevereiro, março e abril, a cultura começa o processo de senescência e a entrada em período de dormência.

Observando a resposta do NDVI da cultivar 'Gala' nas datas avaliadas em função dos tratamentos (Figura 4), constatou-se que nos meses de outubro, março e abril não houve diferença estatística significativa para os diferentes tipos de poda aplicados na cultura. Já nos meses de novembro, dezembro e fevereiro, o tratamento com poda mecanizada durante o outono apresentou maior NDVI que o tratamento com poda padrão. Isso se deve ao fato de que, na poda padrão, é realizada a retirada de ramos pontuais, conhecidos como ramos “ladrões”, que competem diretamente com os frutos por fotoassimilados. Por outro lado, na poda mecanizada há a retirada de uma maior quantidade de ramos, buscando manter a estrutura trapezoidal da planta, proporcionando aumento na penetração de luz no dossel da planta e, conseqüentemente, maior NDVI.




FIGURA 4. Resposta do NDVI da cultivar ‘Gala’ nas datas avaliadas, em função dos tratamentos de poda. **NDVI response of the cultivar 'Gala' on the dates evaluated according to the treatments.**

De forma geral, os resultados obtidos vão ao encontro da observação reportada por Zhang *et al.* (2003), de que a utilização do índice de vegetação por diferença normalizada (NDVI) permite o monitoramento dinâmico da vegetação em larga escala de forma ecologicamente significativa, sem exigir pré-processamento de dados.

**CONCLUSÃO:** O tipo e a época de poda influenciam diretamente os valores do NDVI. A altura na qual a avaliação é realizada também influencia na resposta deste índice de vegetação na cultivar ‘Gala’. Dessa forma, o emprego do NDVI se mostra uma ferramenta útil na avaliação do comportamento espectral de macieiras desta cultivar.

#### AGRADECIMENTOS:

**AGRADECIMENTOS:** À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão de bolsa de mestrado, possibilitando dedicação integral às atividades acadêmicas. À empresa Campi Frutas, por fornecer a área para realização do experimento.

#### REFERÊNCIAS

AMARAL, L.R.; MOLIN, J.P. **Sensor óptico no auxílio a recomendação de adubação nitrogenada em cana-de-açúcar.** Pesquisa Agropecuária Brasileira, v.46, n.12, p.1633- 1642, 2011.

KORBAN, S.S.; SKIRVIN, R.M. **Nomenclature of the cultivated apple.** HortScience, Alexandria, v.19, n.2, p.177–180, 1984.



PHIPPS, J. B. et al. **A checklist of the subfamily Maloideae (Rosaceae)**. Canadian Journal of Botany, Canadá, v.68, n.10, p.2209- 2269, 1990.

RAPAPORT, T. et al. **The Effect of Differential Growth Rates across Plants on Spectral Predictions of Physiological Parameters**. PLOS ONE, São Francisco, v. 9, n. 2, 2014. Disponível em: <<https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0088930>>. Acesso em: 21 de abril de 2022.

RUFATO, A. R. **Podando macieiras no sistema Tall Spindle**. A Vindima. Flores da Cunha, RS, p. 7-7. jun. 2016. Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/148318/1/A-vindima-junho-85-p72016.pdf>> Acesso em: 21 de abril de 2022.

ZHANG, X. *et al.* Monitoring vegetation phenology using MODIS. **Remote Sensing of Environment**, [S.L.], v. 84, n. 3, p. 471-475, mar. 2003. Elsevier BV. [http://dx.doi.org/10.1016/s0034-4257\(02\)00135-9](http://dx.doi.org/10.1016/s0034-4257(02)00135-9).



# ESTIMATIVA DO VIGOR VEGETATIVO DE CAFEIROS ARÁBICA UTILIZANDO SENSOR RGB EMBARCADO EM VEÍCULO AÉREO NÃO-TRIPULADO

Samuel de Assis Silva<sup>1</sup>; João Mendes Cicarini Hott<sup>2</sup>; Levi Fraga Pajehú<sup>3</sup>; Julião Soares de Souza Lima<sup>4</sup>

<sup>1</sup>Eng. Agrônomo, Professor - Depto. Engenharia Rural, CCAE, UFES, Alegre-ES. samuel.assilva@gmail.com / (28) 9 9988-2927; <sup>2</sup>Discente, Graduando em Agronomia - Depto. Engenharia Rural, CCAE, UFES, Alegre-ES; <sup>3</sup>Eng. Agrônomo, Doutorando - PPGAG, CCAE, UFES, Alegre-ES; <sup>4</sup>Eng. Agrícola, Professor - Depto. Engenharia Rural, CCAE, UFES, Alegre-ES

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** A produção de café arábica se destaca como uma das principais fontes de renda da agricultura capixaba. O uso de veículo aéreo não tripulado (VANT) tem se tornado uma ferramenta importante no monitoramento e na tomada de decisão no manejo dos cultivos agrícolas de forma rápida e eficiente utilizando técnicas de sensoriamento remoto. O estudo do vigor vegetativo, através de índices de vegetação (IV) calculados com dados obtidos por sensores ópticos, permite identificar a saúde e o desenvolvimento vegetativo das plantas. Com este trabalho, objetivou-se avaliar o uso do IV MPRI como indicador vegetativo em lavoura cafeeira esqueletada e sua correlação com NDVI. Foram coletadas imagens aéreas da área em estudo a cada dois meses utilizando sensores ópticos multiespectral e RGB embarcados em VANT. Foram utilizados modelos lineares de regressão espacial buscando prever o NDVI através do MPRI. Os dados médios de NDVI se mantiveram entre 0,5 a 0,7 e de MPRI -0,1 a 0,2, com R<sup>2</sup> variando entre 75,82 a 86,09% e r variando entre 0,8707 a 0,9278. Além disso, o CDRm se manteve próximo a 5% e menor que 10%. De modo geral, os índices estudados foram capazes de representar as fases fenológicas do cafeeiro e apresentaram correlação entre si.

**PALAVRAS-CHAVE:** Cafeicultura; MPRI; Agricultura digital

## ESTIMATED VEGETATIVE VIGOR OF ARABICA COFFEE TREES USING RGB SENSOR BOARDED IN UNMANNED AERIAL VEHICLE

**ABSTRACT:** The yield of arabica coffee stands out as one of the main sources of income for agriculture in Espírito Santo. The use of unmanned aerial vehicle (UAV) has become an important tool in monitoring and decision making in the management of agricultural crops quickly and efficiently using remote sensing techniques. The study of vegetative vigor, through vegetation indices (VI) calculated with data obtained by optical sensors, makes it possible to identify the health and vegetative development of plants. The objective of this work was to evaluate the use of IV MPRI as a vegetative indicator in skeletonized coffee crops and its correlation with NDVI. Aerial images of the study area were collected every two months using multispectral and RGB optical sensors embedded in UAVs. Linear spatial regression models were used to predict the NDVI through the MPRI. The mean data for NDVI remained between 0.5 to 0.7 and for MPRI -0.1 to 0.2, with R<sup>2</sup> ranging from 75.82 to 86.09% and r ranging from 0.8707 to 0.9278. In addition, the CDRm remained close to 5% and less than 10%. In general, the studied indices were able to represent the phenological phases of the coffee plant and presented correlation between them.

**KEYWORDS:** Coffee growing; MPRI; Digital Agriculture

**INTRODUÇÃO:** O sensoriamento remoto (SR) é uma importante ferramenta no monitoramento dos cultivos agrícolas auxiliando de forma eficiente no processo de tomada de decisão. Através do SR é possível a obtenção de informações sem que haja contato físico entre o alvo e o sensor, sendo esses últimos tradicionalmente embarcados em satélites, aeronaves pilotadas e balões (SHIRATSUCHI et al., 2014). Com o avanço tecnológico, os sensores passaram a ser embarcados também em plataformas mais sofisticadas como veículos aéreos não tripulados (SHIRATSUCHI et al., 2014).

Para a cafeicultura, a utilização do Sensoriamento Remoto a partir de veículos aéreos não tripulados (VANT) no monitoramento das lavouras é sinal do avanço tecnológico. Entretanto, observa-se que o alto custo de câmeras multiespectrais tem se tornado um impeditivo para a implementação do uso de VANT em diferentes áreas, em especial, naquelas de pequeno a médio porte e onde o investimento ainda é reduzido.

A maior parte dos índices de vegetação (IV) utilizados na agricultura são calculados envolvendo bandas espectrais além do espectro eletromagnético do visível. O IV que mais tem se destacado nessa área é o Normalized Difference Vegetation Index (NDVI), no qual destaca-se a necessidade da utilização de sensores ópticos para a captura da banda infravermelho proveniente radiação eletromagnética (REM) e também do vermelho refletidas pela superfície dos dosséis (VIAN et al., 2021). Como esse índice depende da banda do infravermelho próximo o seu cálculo somente pode ser realizado a partir dos produtos de sensores multiespectrais.

Pensando na limitação de alguns sensores Yang et al. (2008) desenvolveu um IV que relaciona apenas bandas do espectro eletromagnético do visível, podendo ser calculado a partir dos produtos de sensores óticos RGB. O IV Modified Photochemical Reflectance Index (MPRI), desenvolvido por Yang et al. (2008) é baseado na diferença normalizada entre as bandas da região do verde e do vermelho, portanto independentemente da banda do infravermelho (LINHARES; ROCHA; AMARAL, 2013). Diferentes autores (GONÇALVES et al., 2017; BARBOSA et al., 2019; MAGALHÃES et al., 2019) vêm utilizando o MPRI em estudos envolvendo agricultura, relatando que, em determinadas condições esse IV se torna uma alternativa de baixo custo para adoção de sensoriamento remoto aéreo para o monitoramento das culturas agrícolas. Apesar desse fato, os mesmos autores reforçam a necessidade de se estudar a correlação entre este índice e os multiespectrais para diferentes alvos da vegetação a fim de se comprovar de fato o uso do MPRI como indicador vegetativo.

Neste sentido, este estudo se propôs a avaliar o vigor vegetativo cafeeiro arábica através de VANT buscando, complementarmente, avaliar o grau de correlação dos IV NDVI e MPRI.

**MATERIAIS E MÉTODOS:** O estudo foi realizado, em uma lavoura comercial de café arábica localizada no município de Ibatiba, na Microrregião de Planejamento do Caparaó, no estado do Espírito Santo. O experimento foi conduzido em uma área inclinada onde foi realizado o nivelamento das entrelinhas de plantio de café através do que tem sido conhecido como microterraceamento. O solo da lavoura foi classificado de acordo com o Sistema Brasileiro de Classificação de Solo (SANTOS et al., 2018) como Latossolo Vermelho-Amarelo.

O manejo da lavoura é realizado em sistema de safra zero, com o intuito de minimizar o efeito da bienalidade. Neste sistema, a condução se dá em três safras produtivas e uma vegetativa, sendo para tal realizada, após a terceira safra produtiva, uma poda por esqueletamento. Este estudo se concentrou na avaliação dos diferentes índices para a descrição da capacidade de rebrota das plantas de café. Os cafeeiros cultivados na lavoura foram esqueletados no mês de outubro de 2020.

Para atingir os objetivos propostos na pesquisa foram realizadas coletas de imagens aéreas da área em estudo a cada dois meses. Os aerolevantamentos foram realizados buscando-se contemplar as fases fenológicas do cafeeiro durante um ano agrícola.

Foi utilizado um sensor ótico RGB CMOS equipado com lentes FOV 84° 8.8 mm/24 mm, que captura segmentos dos comprimentos de onda do espectro eletromagnético do visível: vermelho (R - red); verde (G - green), e; azul (B - blue). Adicionalmente foi utilizado um sensor ótico multiespectral RedEdge MX equipado com lentes 47.9° HFOV 5.4 mm, que captura segmentos dos comprimentos de onda do espectro eletromagnético do visível (R, G e B), do rededge e do infravermelho próximo (NIR).

Ambos sensores foram embarcados em um VANT multirrotor modelo Phantom 4 Pro. O sensor RGB é item de fábrica no modelo do VANT enquanto que o multiespectral foi embarcado utilizando suporte específico desenvolvido em impressora 3D.

Os voos automatizados foram realizados bimestralmente respeitando a janela de voo de 11 às 13h e seguindo planejamento pré-estabelecido. Os voos foram realizados a uma altura máxima de 120m e o número de cenas

(imagens) obtidas por voo, bem como a velocidade e as sobreposições laterais e horizontais foram definidas após testes preliminares.

Foram realizadas calibrações geométricas das imagens de forma a eliminar distorções causadas pelas características internas da câmera. As calibrações radiométricas foram realizadas para converter os números digitais (ND) para valores físicos de reflectância. As calibrações radiométricas foram realizadas a partir da resposta espectral de alvos de referência espalhados por toda a extensão da área e também a partir dos acessórios de calibração de imagens que acompanham o sensor multiespectral.

As imagens calibradas foram processadas para obtenção dos mosaicos de ortofotos (ortomosaicos) utilizando o software livre OpenDroneMap (Drone Mapping Software). Foram utilizados, para aumentar a precisão posicional dos ortomosaicos, 15 pontos de controle por fotointerpretáveis distribuídos de forma estratégica por toda a extensão da área. Os pontos de controle foram georreferenciados utilizando um receptor GNSS de precisão subcentimétrica.

O vigor vegetativo das plantas foi estimado utilizando índices de vegetação calculados a partir dos valores de reflectância da copa dos cafeeiros. Foi utilizado o Índice de Reflectância Fotoquímico Modificado (MPRI) proposto por Yang et al. (2008). O MPRI é um índice baseado no espectro eletromagnético do visível e consiste na diferença normalizada entre as bandas da região do verde e do vermelho, sendo independente de uma banda do infravermelho, e estimado pela equação:

$$MPRI = \frac{(G - R)}{(G + R)}$$

Em que: G = valores de reflectância na banda do verde (green), e; R = valores de reflectância na banda do vermelho (red).

O MPRI foi calculado a partir da resposta espectral dos cafeeiros detectada pelo sensor RGB CMOS que equipa (de fábrica) o VANT Phantom 4 Pro, visando oferecer uma possibilidade de monitoramento das lavouras sem a necessidade de sensores multiespectrais. Essa metodologia está alicerçada no fato da existência, segundo Yang et al. (2008), de semelhança na relação infravermelho próximo x vermelho com a relação verde x vermelho.

Visando avaliar a semelhança entre as relações comentadas por Yang et al. (2008), os valores de MPRI foram correlacionados com os valores do Índice de Vegetação da Diferença Normalizada (NDVI). O NDVI é um índice de vegetação multiespectral e consiste na diferença normalizada entre as bandas da região do infravermelho próximo e do vermelho e é estimado pela equação:

$$NDVI = \frac{(NIR - R)}{(NIR + R)}$$

Em que: NIR = valores de reflectância na banda do infravermelho próximo, e; R = valores de reflectância na banda do vermelho (red).

A correlação entre os índices foi mensurada utilizando o coeficiente de correlação de Pearson ao nível de 5% de probabilidade. Essa análise foi utilizada também para avaliar se os dois índices de vegetação MPRI e NDVI são capazes de expressar o mesmo comportamento espacial e temporal para o vigor vegetativo das plantas. Por não ser influenciado por valores absolutos, o coeficiente de Pearson permite avaliar se a distribuição espacial dos índices foi igual independentemente da fase fenológica das plantas.

Visando prever os valores de NDVI e facilitar a interpretação da resposta de vigor vegetativo mensurado pelo MPRI, foi utilizado modelos lineares de regressão espacial. Foi considerado como variável dependente os valores de NDVI mensurados no tempo “i” e como variável independente os valores de MPRI mensurados no tempo “i”. Os coeficientes de regressão ajustados ( $\beta_0$  - valores do intercepto, e;  $\beta_1$  - inclinação da reta), tiveram a significância testada para um nível de 5% de probabilidade.

As predições foram realizadas para todos os períodos avaliados, gerando n equações para m períodos. A plausibilidade de utilização de um único modelo para todo o período ou a necessidade de modelos específicos para cada fase fenológica foi avaliada a partir da semelhança (ou não) entre os coeficientes da regressão, valores de R2 (coeficiente de determinação) e distribuição dos resíduos.


Para avaliar a acurácia dos modelos de regressão foi utilizado o coeficiente de desvios relativos. Essa análise permite descrever os desvios pontuais e médios entre os valores absolutos do NDVI predito em relação ao NDVI calculado. Para isso foram calculados os coeficientes de desvios relativos pontual (CDRi) e médio (CDRm), conforme as seguintes equações:

$$CDR_i = \left( \frac{NDVI_{pred} - NDVI_{calc}}{NDVI_{calc}} \right) * 100$$

$$CDR_m = \sum_{i=1}^n |CDR_i| / n$$

em que: CDRi = coeficiente de desvio relativo pontual (%); CDRm = coeficiente de desvio relativo médio absoluto (%); n = número de pontos amostrais; NDVI<sub>pred</sub> = valor pontual de NDVI predito a partir do MPRI; NDVI<sub>calc</sub> = valor pontual de NDVI calculado a partir das imagens multiespectrais.

**RESULTADOS E DISCUSSÃO:** Os resultados da análise estatística para os índices vegetativos (IV) NDVI e MPRI mensurados com o uso de VANT, encontram-se na Figura 1. Observa-se que os valores médios de NDVI se mantiveram entre 0,5 e 0,7 e para o MPRI -0,1 e 0,2. Além disso, nota-se que tanto para o NDVI quanto para o MPRI os dados apresentaram maior variabilidade no mês de fevereiro/2021 e menor variabilidade em maio/2021.



**FIGURA 1. Box-plot do NDVI e do MPRI mensurados com sensoriamento remoto aéreo em lavoura cafeeira microterraceada. Box-plot of NDVI and MPRI measured with aerial remote sensing in a microterrace coffee crop.**

A poda do cafeeiro por esqueletamento é considerada um manejo drástico que consiste na retirada de grande parte dos ramos plagiótropico e necessita de um período de recuperação de dois anos (SILVA et al., 2016). Com isso, o corte de galhos folhosos faz com que o cafeeiro esqueletado apresente baixo vigor vegetativo nos primeiros meses após o manejo. Dessa forma, observa-se que este fato está associado aos menores valores dos índices NDVI e MPRI para o mês de dezembro/2020 e fevereiro/2021.

Posteriormente, com a continuidade do desenvolvimento vegetativo e o surgimento de novas folhas a vegetação se torna mais ativa, dessa forma a resposta espectral do cafeeiro tende a ser maior na região do infravermelho e do verde devido a relação entre estas bandas (YANG et al., 2018; VILLAR; ROSAS; PINTO,

2020). Dessa forma, o aumento dos índices NDVI e MPRI nos meses de maio/2021 e julho/2021 indica continuidade no desenvolvimento vegetativo do cafeeiro esqueletado.

Na Figura 2 é possível observar os mapas representativos da variação temporal do IV NDVI e MPRI para os meses de dezembro/2020 e fevereiro/2021. Esses mapas são apresentados apenas para exemplificar a evolução temporal dos diferentes índices. Para o NDVI os mapas apresentam uma mancha no canto superior esquerdo do mapa onde encontra-se maior biomassa, observa-se que não houve grande variabilidade entre os dados observados nos meses de dezembro/2020 e janeiro/2021.

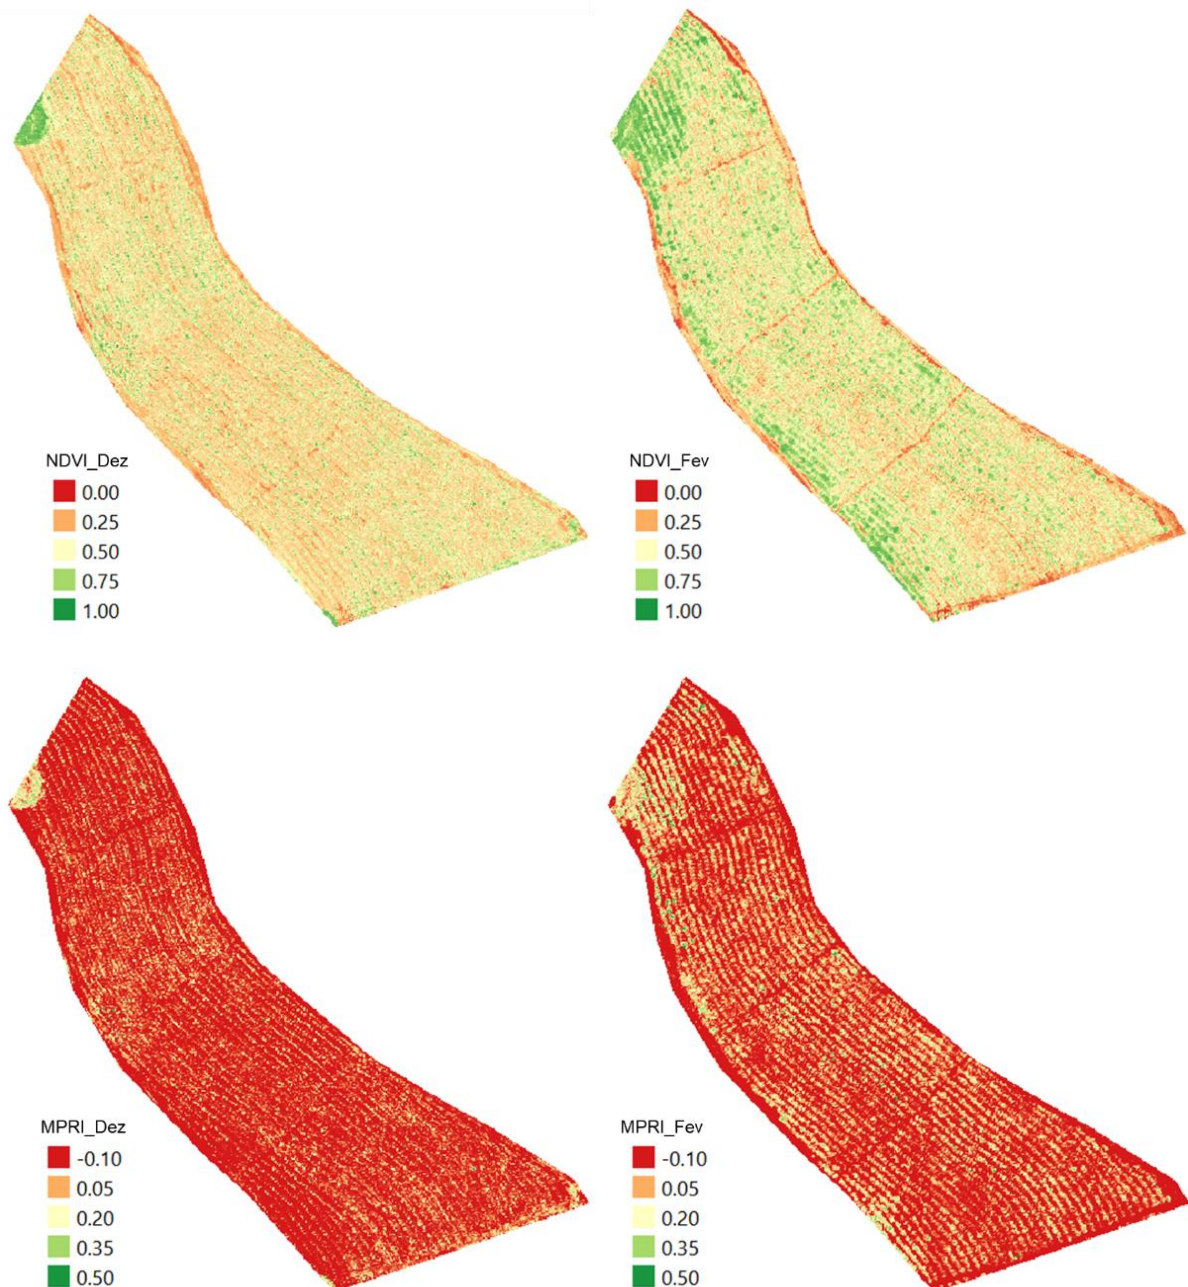


FIGURA 2. Mapas temáticos da variação temporal do NDVI e do MPRI em duas diferentes datas dentro do período de estudo. **Thematic maps of the temporal variation of NDVI and MPRI on two different dates within the study period.**

Ao observar os mapas representativos do MPRI percebe-se que os resultados não apresentam grande variabilidade entre os meses de dezembro/2020 e janeiro/2021, se comportando de forma semelhante ao obtido estudando o NDVI. Dessa forma, nota-se que este fato está associado a correlação existente entre os dois índices, o que corrobora com os resultados obtidos por Linhares et al. (2013) que validam o uso do MPRI como indicador vegetativo.

Na Figura 3 encontram-se os gráficos de correlação e regressão linear entre o NDVI e o MPRI durante o período estudado, além do coeficiente de correlação linear de Pearson ( $r$ ) e o coeficiente de determinação ( $R^2$ ). Observa-se através que os valores de  $R^2$ , variaram entre 75,82 e 86,09%, isso mostra que os modelos gerados se ajustam bem aos dados.

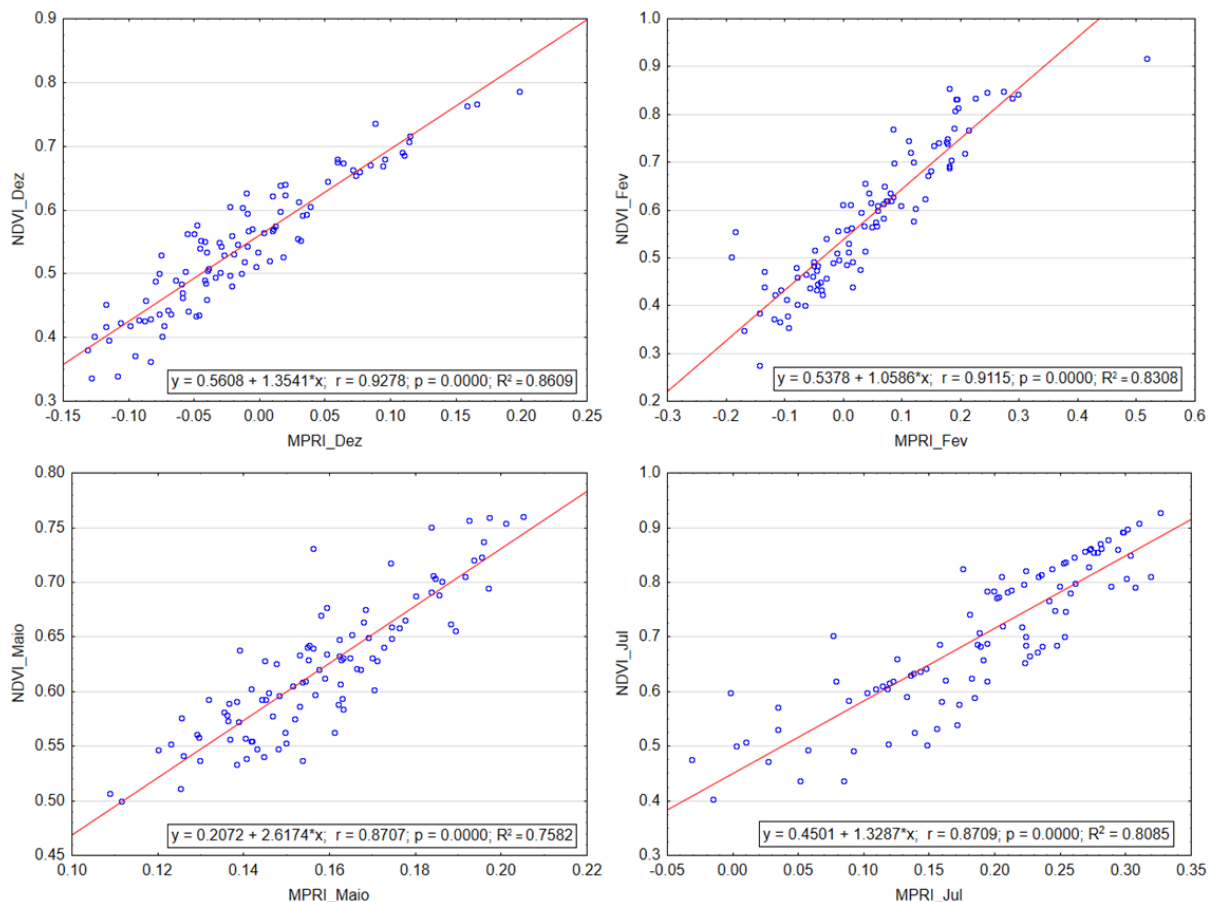


FIGURA 3. Correlação e regressão linear entre os valores de NDVI e MPRI entre os diferentes períodos de estudo. **Linear correlation and regression between NDVI and MPRI values between different study periods.**

Observando a curva e os valores de  $r$ , entre 0,8707 e 0,9278, é possível perceber que o MPRI apresenta correlação forte e positiva com o NDVI, corroborando com o que foi observado nos mapas representativos (Figura 2). Em estudo realizado por Sampaio et al. (2020) os autores obtiveram correlação positiva, com  $r$  de 0,61, entre o MPRI obtido através sensoriamento remoto aéreo e orbital mostrando que o uso do MPRI como indicador vegetativo com diferentes plataformas.

Além disso, outro parâmetro utilizado no monitoramento da vegetação é o Percentual de Verde (PV), que busca verificar a cobertura vegetal efetivamente verde ao longo de uma área (LINHARES, 2016). Ao estudar a correlação entre o MPRI com o Percentual de Verde, Linhares (2016) obteve resultados de correlação positiva, com  $r$  superior a 0,95, validando a correlação entre os dois índices e validando o MPRI como indicador vegetativo.

Os coeficientes de desvios relativos pontuais (CDRi) e médios (CDRm) encontram-se na Figura 4. Através destes dados pode-se observar se há similaridade entre o NDVI predito por regressão e o NDVI calculado a partir de dados obtidos por câmera multiespectral, uma vez que o menor potencial informa maior similaridade entre os dados (CHERUBIN, 2015).



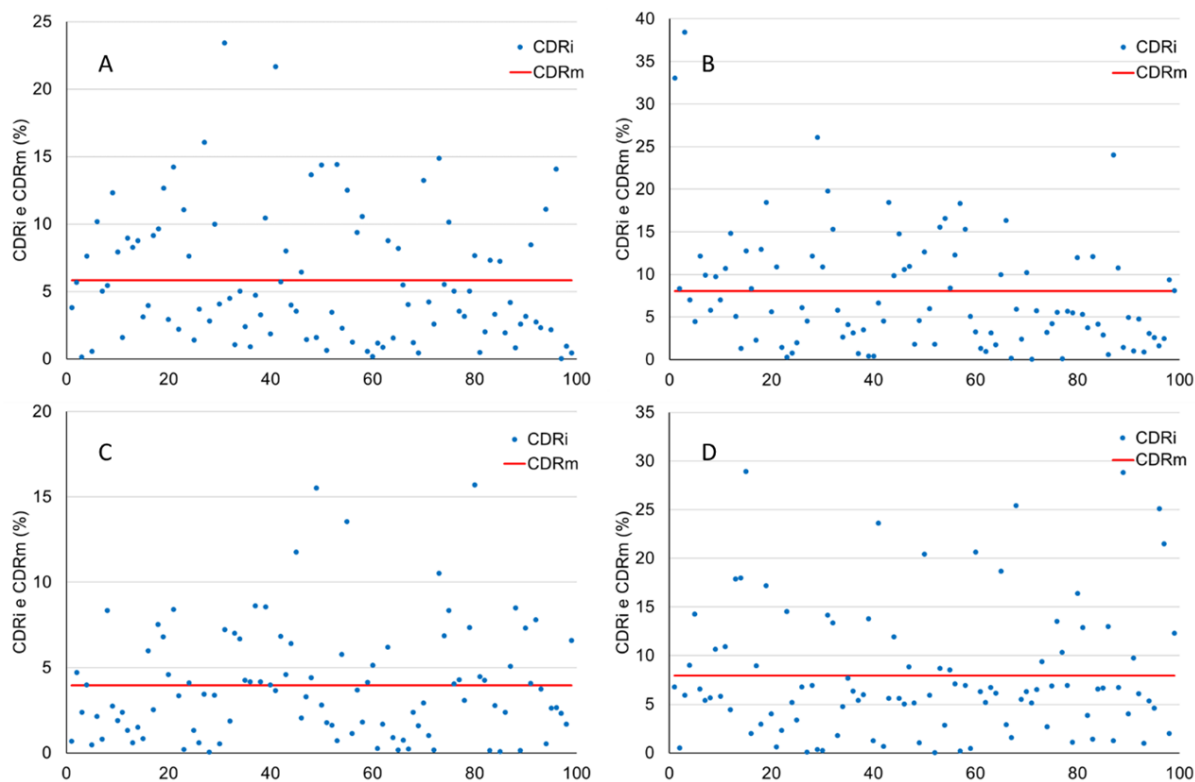


FIGURA 4. Coeficientes de desvios relativos pontuais (CDRi) e médios (CDRm) entre o NDVI predito por regressão e o NDVI calculado a partir das imagens multiespectrais: A) Dez\_20; B) Fev\_21; C) Maio\_21, e; D) Jul\_21. **Point (CDRi) and mean (CDRm) relative deviation coefficients between the NDVI predicted by regression and the NDVI calculated from the multispectral images: A) Dec\_20; B) Feb\_21; C) May\_21, and; D) Jul\_21.**

É possível notar que há similaridade entre o NDVI predito por regressão e o NDVI calculado através de dados obtidos com câmera multiespectral, devido os valores de CDRm se manterem próximos a 5% e abaixo de 10%. Dessa forma, é possível reforçar a correlação positiva existente entre o IV MPRI e o NDVI, assim, viabilizando o uso de câmeras RGB para o monitoramento vegetativo.

Apesar da correlação existente entre os IVs NDVI e MPRI já observada por alguns autores, na literatura há poucos estudos que utilizam o MPRI, principalmente na cultura do café.

**CONCLUSÃO:** Através do sensoriamento remoto aéreo foi possível analisar o comportamento temporal do vigor vegetativo do cafeeiro.

O MPRI apresentou correlação forte e positiva com o NDVI, assim, podendo ser utilizado para prever o NDVI auxiliando na interpretação no estudo do vigor vegetativo.

O uso de sensor óptico RGB embarcados em VANT é passível de ser utilizado como ferramenta de Agricultura de Precisão e Digital para o monitoramento do vigor vegetativo em cafeeiro arábica.

#### AGRADECIMENTOS:

Ao CNPQ (Conselho Nacional de Desenvolvimento Científico e Tecnológico) e a FAPES (Fundação de Amparo à Pesquisa e Inovação do Espírito Santo) pelo financiamento para a execução do presente trabalho.

#### REFERÊNCIAS

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.

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. **Pesq. agropec. bras.**, Brasília, v. 50, n. 2, p. 168-177, fev. 2015.

CONAB. **Acompanhamento da safra brasileira: café**. v. 8, safra 2021.

GONÇALVES, L.M.; BARBOSA, B.D.S.; FERRAZ, G.A.S.; MACIEL, D.T.; SANTOS, H.F.D. Variabilidade espacial e temporal do índice vegetação MPRI aplicado às imagens de grama são carlos obtidas por aeronave remotamente pilotada. **Brazilian Journal of Biosystems Engineering**. v. 11, n. 4, p. 340-349, 2017.

LINHARES, M.M.A. **Uso de veículo aéreo não tripulado na determinação de índice de vegetação em área de pastagens em Nova Mutum-MT**. Dissertação (Mestrado em Geografia) - Universidade Federal de Goiás, Instituto de Estudos Socioambientais (Iesa), Programa de Pós-Graduação em Geografia, Goiânia, 2016.

LINHARES, M.M.A.; ROCHA, N.C.C.R.; AMARAL, B.A.S.A. Análise do índice MPRI como indicador vegetativo através da correlação do mesmo com o índice NDVI. IN: **Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, Foz do Iguaçu, PR, Brasil, 13 a 18 de abril de 2013, INPE.

MAGALHÃES, L.P.; TREVISAN, L.R.; GOMES, T.N.; ROSSI, F. Índice de vegetação ajustado ao solo – SAVI adaptado: Proposta para caracterizar cobertura vegetal do solo. **Simpósio Nacional de Instrumentação Agropecuária**, 2009.

SAMPAIO, H.S.; BOURSCHEIDT, V.; SERRACINI, L.H.; JORGE, L.A.C.; BETTIOL, G.M.; BERMARDI, A.C.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, H.G.; JACOMINE, P.K.T.; ANJOS, L.H.; OLIVEIRA, V.A.; LUMBRERAS, J.F.; COELHO, M.R.; CUNHA, T.J.F. **Sistema Brasileiro de Classificação de Solos**. Brasília, Embrapa Solos, Brazil. 2018. p. 353.

SHIRATSUCHI, J.S.; BRANDÃO, A.N.; VICENTE, L.E.; VICTORIA, D.A.; DUCATI, J.R.; OLIVEIRA, R.P.; VILELA, M.F. Sensoriamento Remoto: conceitos básicos e aplicações na Agricultura de Precisão. IN: BERNARDI, A.C.C.; NAIME, J.M.; RESENDE, A.V.; BASSOI, L.H.; INAMASU, R.Y. **Agricultura de Precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014.

SILVA, T.M.A.; VALENTE, D.S.M.; PINTO, F.A.C.; QUEIROZ, D.M.; SANTOS, N.T. Sensor system for acquisition of vegetation indexes. **Rev. bras. eng. agríc. ambient**. v. 25, n. 4. Abril 2021.

VIAN, A.L.; BREDEMEIER, C.; DRUM, M.A.; PIRES, J.L.F.; FOCHESSATTO, E. Vegetation sensors as a tool for plant population identification and corn grain yield estimation. **Pesqui. Agropecu. Trop**. v. 51. 2021.

VILLAR, F.M.M.; ROSAS, J.T.F.; PINTO, F.A.C. Imagens e Sensoriamento Remoto Aplicado à Gestão Agrícola. IN: QUEIROZ, D.M.; VALENTE, D.S.M.; PINTO, F.A.C.; BORÉM, A. **Agricultura Digital**. 1ed. Viçosa, MG: UFV, 2020. p. 66-80.

YANG, Z.; WILLIS, P.; MUELLER, R. Impact of Band-Ratio Enhanced AWIFS Image to Crop Classification Accuracy. **Proc. Pecora**. 2008.



# **6. Técnicas de análise de dados**

# PLATAFORMA DE INTERNET DAS COISAS PARA MONITORAMENTO DE PRODUTIVIDADE E BEM-ESTAR ANIMAL EM SISTEMAS DE INTEGRAÇÃO LAVOURA-PECUÁRIA-FLORESTA

Eduardo Antonio Speranza<sup>1</sup>; Roberto Hiroshi Higa<sup>4</sup>; Marcos Cezar Visoli<sup>2</sup>; Claudinei Martins<sup>5</sup>; Camilo Carromeu<sup>3</sup>

<sup>1</sup>Bel. Ciência da Computação, Analista - Embrapa Agricultura Digital, Campus da Unicamp, Campinas, SP. eduardo.speranza@embrapa.br / (19) 9 8138-1676; <sup>2</sup>Bel. Ciência da Computação, Pesquisador - Embrapa Agricultura Digital, Campus da Unicamp, Campinas, SP; <sup>3</sup>Bel. Ciência da Computação, Analista - Embrapa Gado de Corte, Campo Grande, MS; <sup>4</sup>Engenheiro Elétrico, Pesquisador - Embrapa Agricultura Digital, Campinas, SP; <sup>5</sup>Analista de Sistemas, Pesquisador e Coordenador de Projetos - CPQD, Campinas, SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** A Internet das Coisas (IoT) é uma tecnologia digital emergente em empresas e prestadores de serviço para agronegócio, podendo ser utilizada em temas como modelos de estimativa de produtividade e bem-estar animal. Por sua vez, o sistema de integração lavoura-pecuária-floresta (ILPF) tem se tornado cada vez mais sustentável, com potencial de retorno econômico e de benefícios ambientais significativos. Neste trabalho, é apresentada uma proposta de plataforma baseada em IoT para monitoramento de produtividade e bem-estar animal de bovinos para sistemas de produção ILPF. O objetivo dessa plataforma é fornecer ao produtor informações em tempo real para suporte a tomada de decisão no que diz respeito ao manejo de animais para obtenção de maiores produtividades e produto final de melhor qualidade para o consumo.

**PALAVRAS-CHAVE:** Internet das Coisas; Pecuária de Precisão; Integração Lavoura-Pecuária-Floresta.

## INTERNET OF THINGS PLATFORM FOR YIELD MONITORING AND ANIMAL WELFARE IN CROP-LIVESTOCK-FOREST INTEGRATION SYSTEMS

**ABSTRACT:** The Internet of Things (IoT) is an emerging digital technology in companies and service providers for agribusiness, and can be used in topics such as yield estimation models and animal welfare. In turn, the integrated crop-livestock-forest (ILPF) system has become increasingly sustainable, with potential for economic returns and significant environmental benefits. In this work, a proposal for an IoT-based platform for monitoring bovine yield and animal welfare for ILPF production systems is presented. The objective of this platform is to provide the farmer with real-time information to support decision-making regarding the management of animals to obtain higher yields and a better quality final product for consumption.

**KEYWORDS:** Internet of Things; Precision Livestock; Crop-Livestock-Forest-Integration

**INTRODUÇÃO:** O uso de conceitos de internet das coisas (IoT) para automação da coleta e transmissão de dados em campos agrícolas contribui para o desenvolvimento de modelos analíticos mais precisos e de aplicativos que forneçam informações que contribuem para uma melhor gestão e produção agrícola. Segundo pesquisa realizada por Bolfe et al. (2020), IoT está entre as tecnologias digitais emergentes preferidas para serem incorporadas ao portfólio de empresas e prestadores de serviço que atuam no agronegócio brasileiro. Ainda de acordo com a mesma pesquisa, temas como o bem-estar animal e modelos de estimativa de produtividade estão entre os mais atendidos por essas empresas no que tange ao uso de tecnologias digitais.

O sistema de integração lavoura-pecuária-floresta (ILPF), que consiste na utilização de diferentes sistemas de produção, agrícola, pecuário e florestal dentro de uma mesma área, vem se difundindo ano após ano no Brasil, contando atualmente com uma área estimada em 17 milhões de hectares e um alto nível de satisfação verificado junto aos agricultores e pecuaristas adeptos do sistema (Polidoro et al., 2020). Com isso, o sistema ILPF tem fomentado o crescimento de um mercado sustentável, com potencial de retorno econômico e de benefícios ambientais significativos e com boas perspectivas futuras.

Diversas atividades realizadas durante o ciclo de produção baseado em ILPF podem ser automatizadas e, conseqüentemente, auferir benefícios com o uso de tecnologias IoT. A análise de camadas superficiais e de emissões de gases de efeito estufa por meio de sensores que medem níveis de dióxido de carbono apresentam grande potencial de aplicação nos sistemas produtivos atuais, assim como a aferição da área do piquete e o lote de animais nele inserido quanto ao nível de aderência a protocolos de mercado. Outro benefício observado está relacionado à análise do microclima, quanto às variáveis de temperatura e umidade do ar e velocidade do vento, para cálculo de índices de conforto térmico animal. O simples monitoramento constante dessas variáveis de forma automatizada por meio uma plataforma IoT pode melhorar o manejo dos animais quanto ao bem-estar, a partir de cálculos em tempo real de índices de conforto térmico (Thom, 1958; Buffington et al., 1981). Com relação ao manejo pecuário, aspectos como a umidade e a temperatura do solo e da água do cocho, além das pesagens diárias, monitorados com sensores, proporcionam tomadas de decisão mais precisas no manejo da suplementação da dieta e na movimentação dos animais entre os piquetes.

Considerando esse contexto, o presente trabalho apresenta uma proposta de plataforma baseada em IoT para monitoramento de produtividade e bem-estar animal de bovinos inseridos em sistemas de produção ILPF. O principal objetivo dessa plataforma é fornecer ao pecuarista informações precisas em tempo real, para suporte a tomadas de decisão que visam aumentar o retorno econômico e ambiental e a qualidade e valor agregado do produto final.

**MATERIAIS E MÉTODOS:** A plataforma baseada em IoT para sistemas ILPF proposta neste trabalho se utiliza de três fontes distintas de dados, com foco no desenvolvimento de aplicações para monitoramento do ganho de peso e bem-estar animal: balanças de passagem, que permitem a aferição automática do peso diário dos animais presentes no sistema; estações agrometeorológicas contendo sensores para identificação de variações microclimáticas existentes nos diferentes piquetes do sistema de produção; e cabrestos inteligentes, capazes de fornecer informações relacionadas ao estado de saúde do animal em tempo real, como frequências cardíaca e respiratória. A área, bem como os animais utilizados neste estudo, pertence à Embrapa Gado de Corte, localizada em Campo Grande, MS.

### ***Balanças de passagem***

A Balança de Passagem (BalPass®), atualmente comercializada pela Coimma (COIMMA, 2022), foi criada com o objetivo de auxiliar os pecuaristas a tomarem decisões na propriedade, tornando a gestão mais eficiente, a partir do armazenamento e transmissão via rede de dados do rebanho e a evolução diária de peso dos animais (EMBRAPA, 2019). Essa metodologia permite o acompanhamento da evolução de ganho de peso individual, possibilitando ao produtor controlar o desenvolvimento do rebanho e auxiliar em tomadas de decisão, tais como o descarte de animais que não ganham peso de forma adequada, ou mudanças na dieta de acordo com metas preestabelecidas. A BalPass pode ser instalada na pastagem em local estratégico onde os animais normalmente transitam, como em acessos a bebedouros e cochos de suplementação. A balança utiliza para seu funcionamento um painel de energia fotovoltaico, e o reconhecimento de cada animal quando passa por ela para aferição de peso é realizado por meio de dispositivos (brincos) RFID[1]. Essa mesma tecnologia é utilizada para enviar os dados para a sede da fazenda ou para um concentrador de dados mais próximo. Deste ponto, os dados são enviados para uma plataforma em nuvem, com acesso permitido via internet aos respectivos produtores. Além do painel solar fotovoltaico e dos dispositivos para recepção (leitor de brincos) e envio de dados (antena) via RFID, também compõem a BalPass uma central de processamento de dados, sensores infravermelhos e barras de pesagem (FIGURA 1).



FIGURA 1. Balança de passagem BalPass, composta por antena para envio de dados via RFID (1), painel de energia fotovoltaico (2), central de processamento de dados (3), placa para leitura de dispositivos RFID (4), sensores infravermelhos (5) e barras de pesagem (6). Fonte: COIMMA (2022). **BalPass pass-through scale, consisting of an antenna for sending data via RFID (1), photovoltaic energy panel (2), data processing center (3), card for reading RFID devices (4), infrared sensors (5) and weighing bars (6).** Source: COIMMA (2022).

Apesar de cada animal ter a possibilidade de, na maioria dos casos, passar pela balança mais de uma vez ao dia, o sistema BalPass fornece ao usuário apenas um valor de pesagem por animal por dia. Esse peso é consolidado por algoritmo de inteligência artificial (IA) (RODRIGUES FILHO et al., 2014) instalado na plataforma em nuvem do fabricante, considerando todos os pesos de cada animal naquele dia e tendências observadas em pesagens consolidadas de dias anteriores.

### *Estações agrometeorológicas*

O efeito das condições ambientais que afetam o bem-estar animal vem sendo estudado na literatura ao longo dos últimos anos. Elementos climáticos como temperatura e umidade relativa do ar, radiação solar e velocidade do vento estão altamente associados com o conforto dos animais e são muito utilizados para o cálculo de índices indicativos dessa situação (OLIVEIRA et al., 2017). A alta disponibilidade de estações agrometeorológicas no mercado, possibilitando a coleta e o envio automatizados de dados via internet, contribui para que novas soluções relacionadas ao bem-estar animal com base em eventos climáticos surjam ao longo do tempo.

Neste trabalho, as estações utilizadas são do modelo ECOD3® (Figura 2), comercializadas pela Metos (METOS, 2022). Esse modelo de estação é composto por sensores de umidade do solo, velocidade e direção do vento, temperatura de bulbo seco e de bulbo úmido, temperatura e umidade relativa do ar e radiação solar.



FIGURA 2. Estação agrometeorológica ECOD3, com sensores acoplados. Fonte: Embrapa Gado de Corte. **ECOD3 agrometeorological station, with coupled sensors. Source: Embrapa Beef Cattle.**

Essa estação possui memória interna para armazenamento de dados e sistema de transmissão de dados via rede NB-IoT[2]. Assim como a BalPass, a estação ECOD3 também é alimentada por painel solar fotovoltaico. Os dados são recebidos e podem ser visualizados por meio da plataforma em nuvem FieldClimate.

### ***Cabrestos Inteligentes***

Os cabrestos inteligentes instalados em bovinos possibilitam a aquisição de diversos tipos de dados relacionados à um animal em específico, tais como frequência cardíaca e respiratória, temperatura do pelame, radiação ultravioleta, etc. O BEP (Bovine Eletcronic Plaform) (MARIN, 2016), utilizado neste trabalho, é um modelo de cabresto inteligente que vem sendo desenvolvido desde 2017 e atualmente está em fase de prototipação pela empresa Indext (INDEXT, 2022) (FIGURA 3). Uma característica extremamente importante do BEP é que ele é não-invasivo, o que minimiza o estresse e o desconforto do animal durante a sua utilização. Outra característica é que a leitura dos dados pode ser realizada em qualquer momento, sem que seja necessário transportar o animal para outro local. Os dados são transmitidos para um concentrador de dados (*gateway*), via protocolo LoraWan[3], que por sua vez são transmitidos via Wi-Fi para um roteador conectado à internet. A solução BEP ainda contém uma aplicação em nuvem que realiza o tratamento dos dados e fornece as informações de cada animal em tempo real para o usuário.

A aquisição de dados individuais dos animais com alta frequência proporciona uma série de possibilidades no que tange ao desenvolvimento de aplicações. Alterações mais severas de frequência cardíaca e respiratória em um determinado momento podem indicar que o animal foi submetido a um evento inesperado, enquanto que repetições desses eventos podem evidenciar um problema de saúde mais sério com o mesmo. Desse modo, esses dados viabilizam o desenvolvimento de metodologias relacionadas ao bem-estar animal de forma individual, já incorporando as mudanças de ambiente onde estão.



FIGURA 3. Protótipo de dispositivo BEP instalado em animal. Fonte: Embrapa Gado de Corte. **Prototype of a BEP device installed in an animal. Source: Embrapa Beef Cattle.**

### ***Plataformas para integração de dados***

Conforme mencionado anteriormente, os dispositivos IoT utilizados neste trabalho (balanças de passagem, estações agrometeorológicas e cabrestos inteligentes) possuem sistemas associados para coleta e envio de dados para nuvens proprietárias. Essas nuvens, por sua vez, possibilitam o acesso remoto e seguro via APIs Restful[4] por usuários cadastrados, para que os dados coletados possam ser integrados. Neste trabalho, uma instância específica da plataforma dojot (Dojot, 2022) será utilizada para permitir essa integração. Adicionalmente, as plataformas PlatIAgro (PlatIAgro, 2022) e AgroAPI (Vaz et al., 2017) também serão utilizadas, para prover o desenvolvimento e acesso a algoritmos de inteligência artificial que permitirão a transformação dos dados coletados em conhecimento aplicável por parte do usuário final.

### Área experimental

A área utilizada para este estudo é um campo experimental de 18 ha da Embrapa Gado de Corte, localizada em Campo Grande, MS, com coordenadas geográficas aproximadas O54°42'0'' e S 20°24'36'', denominada "Agrossilvipastoril". Essa área foi dividida em três subáreas (sistemas) para estudo de diferentes situações para as condições de microclima: sistema ILPF com densidade florestal de 89 árvores/ha (ILPF-28); sistema ILPF com densidade florestal de 113 árvores/ha (ILPF-22); e sistema integração-lavoura-pecuária (ILP), para controle (FIGURA 4). Para o experimento, serão utilizados 32 animais com BEPs instalados (12 para cada sistema ILPF e 8 para o sistema ILP), 3 balanças de passagem (uma para cada sistema) e 5 estações agrometeorológicas (2 para cada sistema ILPF e 1 para o sistema ILP). A área também possui sinal de rede 4G disponível, viabilizando a transmissão dos dados pela internet.



FIGURA 4. Imagem da área experimental com identificação dos três sistemas distintos. Fonte: Adaptado de Google Maps. **Image of the experimental area with identification of the three different systems. Source: Adapted from Google Maps.**

- [1] RFID: do inglês *Radio Frequency Identification* – Identificação por Rádio Frequência.
- [2] NB-IoT: do inglês *Narrowband Internet of Things* – internet das coisas em banda estreita.
- [3] LoraWan: protocolo de comunicação de baixo consumo de energia e longo alcance para dispositivos RFID.
- [4] API Restful: Padrão de arquitetura para criação e disponibilização de serviços na Web.

**RESULTADOS E DISCUSSÃO:** A partir da definição dos subsistemas IoT, conforme descrito na seção anterior, foi proposta uma arquitetura geral para a implementação da plataforma proposta neste trabalho (FIGURA 5).



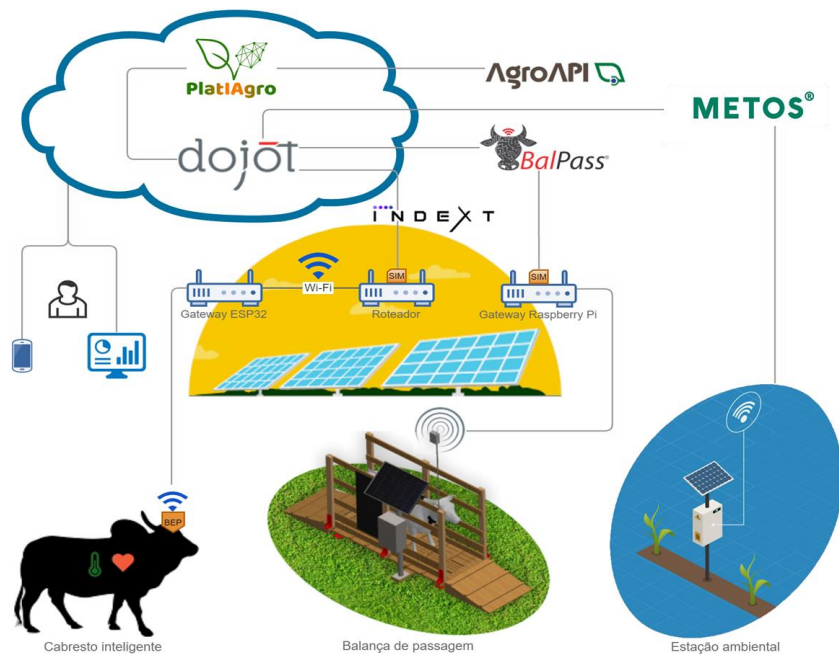


FIGURA 5. Arquitetura geral da plataforma. **General platform architecture.**

Conforme pode ser visualizado na FIGURA 5, os três sistemas de coleta de dados IoT (cabrestos inteligentes, balanças de passagem e estações agrometeorológicas ou ambientais) constituem a camada de coleta de dados do sistema. Os dados coletados pelo BEP em cada animal são transmitidos via protocolo LoraWan para um gateway ESP32[5], que tem a função de retransmitir os dados para um roteador central ligado à internet via rede 4G. Esses dados são automaticamente retransmitidos para a nuvem da Indext, onde são tratados e disponibilizados para acesso pelo usuário. De maneira similar, os dados brutos de pesagem dos animais coletados pelas balanças são transmitidos à um gateway Raspberry PI[6], também ligado à rede 4G e que, por sua vez, são disponibilizados na nuvem da BalPass para acesso pelos usuários. Essa camada, referente aos equipamentos de rede, é constituída por uma estação de campo, com torre de transmissão e painéis solares para alimentação. Finalmente, as estações agrometeorológicas também acessam a internet via rede 4G, proporcionando o envio de dados diretamente à plataforma FieldClimate, onde posteriormente são disponibilizados para os usuários.

Com relação ao intervalo de coleta de dados, BEPs e estações de microclima foram configurados para coletar dados a cada 10 minutos para que, além da possibilidade de uma coleta de dados robusta para futuras análises por algoritmos de IA, possam ser identificados eventos isolados relacionados ao bem-estar dos animais e ao microclima. Com esse intervalo de tempo de coleta, a bateria dos BEPs tem carga suficiente para aproximadamente quatro semanas, intervalo este já comumente utilizado para manejo dos animais e que possibilitará a troca dos BEPs. Já os dados de pesagem, por serem consolidados por algoritmo na nuvem da Indext, são coletados em um intervalo de um dia (um peso por animal por dia).

Para que os dados oriundos das três nuvens privadas possam ser integrados na plataforma dojot, estão sendo desenvolvidos agentes IoT específicos para essa plataforma, capazes de buscar dados a partir de APIs Restful. Esses agentes são executados em intervalos de tempo pré-definidos para verificação de novos dados em cada nuvem privada e, em caso positivo, os mesmos são inseridos na base de dados NoSQL[7] da plataforma dojot. Além da base NoSQL, a dojot possui uma base de dados relacional que possibilita associar os dados originários dos sensores com as entidades referentes aos animais e estações. Os dados armazenados nessa base serão utilizados por aplicativo e aplicação Web, atualmente em desenvolvimento, e poderão ser visualizados de diferentes maneiras pelos usuários.

Também estão em desenvolvimento algoritmos de regressão e lógica fuzzy para as duas principais aplicações a que se destinam os dados coletados: estimativa de peso individual dos animais em datas futuras; e geração de novo indicador de bem-estar animal. Entretanto, para que tenham boa acurácia, esses algoritmos necessitam de boa massa de dados da área experimental, cuja coleta encontra-se ainda em estágio inicial. As informações consolidadas por esses algoritmos, que serão disponibilizadas pelas plataformas PlatiAgro e AgroAPI, também



serão exibidas pelo aplicativo e aplicação Web em desenvolvimento, para auxílio à tomada de decisão por parte do produtor.

[5] ESP32: Padrão de hardware que incorpora recursos como Wifi, bluetooth BLE e microprocessador.

[6] Raspberri PI: Minicomputador completo com todos os componentes distribuídos em placa lógica única.

[7] NoSql: Padrão de banco de dados para armazenamento e análise de dados semiestruturados.

**CONCLUSÃO:** Este trabalho apresentou uma proposta de arquitetura para uma plataforma de IoT para monitoramento de produtividade e bem-estar animal em sistemas ILPF. Sua implantação em área experimental já conta com sensores instalados e dados sendo coletados conforme a arquitetura proposta, porém ainda em fase inicial. Espera-se que o experimento apresentado permita verificar se o conjunto de sensores e softwares que compõem a plataforma são capazes de fornecer informações seguras ao produtor rural, úteis para reduzir custos por meio da utilização de sistemas ILPF, e aumentar a produtividade e a qualidade do produto entregue ao consumidor final.

#### **AGRADECIMENTOS:**

Agradecemos à Huawei do Brasil, pelo financiamento do projeto mencionado neste trabalho e à Embrapa e CPqD pela disponibilidade de infraestrutura e equipe para desenvolvimento do projeto. O projeto mencionado foi concebido a partir da Lei da Informática, e é gerido pela Fundação Arthur Bernardes (Funarbe), por parte da Embrapa; e por contrato EMBRAPII (Empresa Brasileira de Pesquisa e Inovação), por parte do CPqD.

#### **REFERÊNCIAS**

BOLFE, É. L.; Jorge, L. A. D. C.; Sanches, I. D. A.; Luchiari Júnior, A.; da Costa, C. C.; Victoria, D. D. C.; Ramirez, A. R. Precision and digital agriculture: Adoption of technologies and perception of Brazilian farmers. **Agriculture**, v. 10, n. 12, p. 653, 2020.

BUFFINGTON, D.E.; COLLASSO-AROCHO, A.; CANTON, G.H. et al. Black globe-humidity index (ITGU) as comfort equation for dairy cows. **Trans. ASAE**, v.24, p. 711-714. 1981.

COIMMA. **Coimma Troncos e Balanças**. Disponível em: <<https://coimma.com.br>>. Acesso em: 03 mai. 2022.

DOJOT. **Dojot Soluções para IoT**. Disponível em: <<https://dojot.com.br>>. Acesso em 29 abr. 2022.

EMBRAPA. Sistema automático de pesagem ajuda a monitorar rebanho. **Dia de Campo na TV**. Brasília, DF: Embrapa; Campo Grande, MS: Embrapa Gado de Corte, 2019. Programa de TV.

FIELDCLIMATE. **FieldClimate by Pessl Instruments**. Disponível em: <https://www.fieldclimate.com>. Acesso em: 03 mai. 2022.

INDEXT. **Indext Soluções Tecnológicas**. Disponível em: <<https://www.indext.com.br>>. Acesso em 28 abr. 2022.

MARIN, C. **Sistema para aquisição e processamento de temperatura cutânea em bovinos e variáveis ambientais**. Dissertação (Mestrado), Universidade Federal de Mato Grosso do Sul, 2016.

METOS. **Metos Brasil**. Disponível em: <<http://www.metos.com.br>>. Acesso em 02 mai. 2022.

Oliveira, C. C.; Alves, F. V.; de Almeida, R. G.; Gamarra, É. L.; Villela, S. D. J.; Martins, P. G. M. D. A. Thermal comfort indices assessed in integrated production systems in the Brazilian savannah. **Agroforestry systems**, v. 92, n. 6, p. 1659-1672, 2018.

POLIDORO, J. C.; DE FREITAS, P. L.; HERNANI, L. C.; DOS ANJOS, L. H. C.; RODRIGUES, R. D. A. R.; CESÁRIO, F. V.; RIBEIRO, J. L.. The impact of plans, policies, practices and technologies based on the principles of conservation agriculture in the control of soil erosion in Brazil. **Authorea Preprints**, 2020.

PLATIAGRO. **Projeto PlatIAgro – CPQD**. Disponível em <<https://www.cpqd.com.br/inovacao/platiagro/>>. Acesso em 29 abr. 2022.

RODRIGUES FILHO, J. R.; DOS SANTOS NETO, Q. I. Software de gerenciamento para pesagem automatizada de bovinos da Embrapa Gado de Corte utilizando a balança de passagem Coimma/Embrapa. In: Embrapa Gado de Corte-Resumo em anais de congresso (ALICE). In: **JORNADA CIENTÍFICA EMBRAPA GADO DE CORTE**, 9., 2013, Campo Grande, MS.[Anais da..]. Campo Grande, MS: Embrapa Gado de Corte, 2013., 2013.

THOM, E. C. Cooling degree-days airconditioning, heating and ventilating. Atlanta, GA, USA. **Transactions of ASH&VE**, v. 55, p.65-72, 1958

VAZ, G. J.; APOLINÁRIO, D. R. de F.; CORREA, J. L.; VACARI, I.; GONZALES, L. E.; DRUCKER, D. P.; BARIANI, J. M.; EVANGELISTA, S. R. M.; ROMANI, L. A. S. AgroAPI: criação de valor para a Agricultura Digital por meio de APIs. In: **CONGRESSO BRASILEIRO DE AGROINFORMÁTICA**, 11, 2017, Campinas. Ciência de dados na era da agricultura digital: anais. Campinas: Editora da Unicamp: Embrapa Informática Agropecuária, 2017. p. 59-68. SBIAgro 2017.

## DELINEAMENTO DE ZONAS DE MANEJO PARA O PLANEJAMENTO DE EXPERIMENTAÇÃO ON-FARM NA CULTURA DO ALGODÃO

Eduardo Antonio Speranza<sup>1</sup>; Geovana Estevam de Sousa Olim<sup>2</sup>; Ricardo Yassushi Inamasu<sup>3</sup>; Carlos Manoel Pedro Vaz<sup>4</sup>; Lúcio André de Castro Jorge<sup>5</sup>

<sup>1</sup>Cientista da Computação, Analista - Embrapa Informática Agropecuária, Campinas, SP. eduardo.speranza@embrapa.br / (19) 9 8138-1676; <sup>2</sup>Engenheira Agrícola e Ambiental, Assistente de Campo - Grupo Amaggi, Sapezal, MT; <sup>3</sup>Engenheiro Mecânico, Pesquisador - Embrapa Instrumentação, São Carlos, SP; <sup>4</sup>Físico, Pesquisador - Embrapa Instrumentação, São Carlos, SP; <sup>5</sup>Engenheiro Elétrico, Pesquisador - Embrapa Instrumentação, São Carlos, SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** O Brasil é atualmente um dos maiores produtores e exportadores mundiais de algodão. O principal desafio dos produtores é a busca contínua do aumento da produtividade, aliado à qualidade do produto final, com foco no aumento da lucratividade e redução de impactos ao meio ambiente, tornando a produção de algodão no país cada vez mais sustentável. Desse modo, se torna cada vez mais necessária a adoção de técnicas de manejo que envolvam a coleta, análise e intervenção com base em dados, como a agricultura de precisão (AP). A subdivisão das áreas de produção em zonas de manejo (ZM) é uma das formas de se iniciar a adoção da AP em uma área de cultivo agrícola. Este trabalho teve como objetivo principal realizar o delineamento de ZM para uma área de produção de algodão de safra localizada em Sapezal-MT, utilizando técnicas computacionais de agrupamento de dados. A função principal desse delineamento foi auxiliar na estratégia para construção de experimentação *on-farm* para o estabelecimento de recomendações de adubação de cobertura nas diferentes ZM delimitadas para a área de estudo.

**PALAVRAS-CHAVE:** Análise de Agrupamento; Imageamento Aéreo; Produtividade

## DELINEATION OF MANAGEMENT ZONES FOR ON-FARM EXPERIMENTATION IN COTTON PRODUCTION FIELDS

**ABSTRACT:** Brazil is currently one of the largest cotton producers and exporters in the world. The main challenge for farmers is seek for continuous productivity growth, associated with the quality of final product, focusing on increasing profitability and reducing environmental impacts, making cotton production in the country increasingly sustainable. Therefore, it has becoming increasingly necessary to adopt management tools driven by data collection, analysis and intervention, such as precision agriculture (PA). The subdivision of production fields in management zones (MZ) is one effective way to start the PA adoption in an agricultural cultivation area. The main goal of the present study is to perform the delineation of MZ for a cotton production area located in Sapezal-MT, using computing data clustering tools. The main purpose of this delineation is to assist in the strategy of on-farm experimentation for the establishment of nitrogen fertilizer topdressing recommendations in the different MZ delimited for the study cotton field.

**KEYWORDS:** Clustering analysis; Aerial Imaging; Yield

**INTRODUÇÃO:** Ao longo dos últimos anos, o Brasil tem se estabelecido entre os maiores produtores e exportadores mundiais de algodão (ABRAPA, 2020). Na safra 2018/2019, foram produzidos 2,779 milhões de toneladas de algodão em pluma no país, sendo o Estado de Mato Grosso responsável por 67% dessa produção, em uma área plantada aproximada de 1,09 milhões de hectares, o que proporcionou ao Estado uma produtividade média de 1,66 toneladas de pluma de algodão por hectare (CONAB, 2020). A alta produtividade do algodão no Mato Grosso também está relacionada com a qualidade da pluma, que proporciona um alto valor agregado dessa *commodity* no mercado internacional. Com clima e relevo amplamente favoráveis à produção do algodão, o desafio atual dos produtores do Estado é manter o alto patamar de produtividade, sem que seja necessário incrementar os investimentos em insumos e abertura de áreas novas na mesma proporção (FUNDAÇÃO MT, 2020). Desse modo, a adoção de técnicas de manejo com foco na gestão da produção,

como a agricultura de precisão (AP), tem grande potencial em auxiliar de maneira efetiva nesse desafio (BERNARDI et al., 2014). Adicionalmente, o desenvolvimento de tecnologias de informação e comunicação (TICs) capazes de coletar, processar e compartilhar dados de relevo, solo, cultura e clima de uma área de produção que, quando aplicadas na AP, caracterizam o conceito de agricultura digital, potencializa a tomada de decisão pelo produtor com objetivo de reduzir perdas e aumentar a produção com base na gestão da variabilidade espacial. Um dos conceitos que podem ser utilizados para auxiliar o início desse processo é a subdivisão das áreas de produção em unidades de gestão diferenciada (UGD), popularmente conhecidas como zonas de manejo (ZM) (DOERGE, 1999). Essa subdivisão deve se manter relativamente constante ao longo do tempo e, para tanto, deve ser executada considerando a variabilidade natural da área. Desse modo, atributos não antropizados e relacionados principalmente ao solo e a cultura, além do conhecimento do próprio produtor, devem ser utilizados para que sejam obtidos mapas de ZM mais confiáveis. Dentre esses atributos, podem ser destacados: a condutividade elétrica aparente do solo (CEa), que pode ser correlacionada com diversas características do solo; índices de vegetação obtidos a partir de sensoriamento remoto, suborbital ou proximal; e a própria produtividade histórica da área (MOLIN et al., 2015). Este trabalho descreve a metodologia utilizada e os resultados obtidos no delineamento de ZM para um talhão experimental de produção de algodão localizado em Sapezal-MT. Esse delineamento teve como objetivo principal auxiliar na estratégia para construção de experimentação *on-farm* (BULLOCK et al. 2019; SHIRATSUCHI et al. 2019), onde foram estabelecidas, em cada ZM definida, diferentes parcelas virtuais para aplicação de diferentes taxas com quatro repetições[CV1] de adubação nitrogenada [CV2] durante o ciclo produtivo da safra de 2020.

**MATERIAIS E MÉTODOS:** A área de estudo utilizada neste trabalho compreende um recorte (125 ha) de um talhão experimental de expansão de algodão de safra com área total de aproximadamente 170 ha, localizado na Fazenda Tucunaré, em Sapezal-MT, com coordenadas geográficas centrais O 58°52'55'' e S 13°35'06'', pertencente ao grupo Amaggi (FIGURA 1).



FIGURA 1. Recorte do talhão experimental (delimitado em amarelo) que compreende a área de estudo utilizada. Imagem: Google Maps.

Para este experimento, foram coletados, em janeiro de 2019, dados de CEa do solo nas profundidades 0-30 e 0-90 cm, utilizando o sensor de campo Veris 3100® (Veris Technologies, Salina, KS, EUA) (FIGURA 2). Logo após a coleta desses dados, foi realizado o plantio do cultivar de algodão transgênico *WideStrike* (WS) na totalidade da área. Durante o crescimento da cultura, foram coletadas imagens em diversos períodos, utilizando uma aeronave remotamente pilotada (ARP) modelo Matrice 200® (DJI, Shenzhen, China) com câmera RGB de alta resolução espacial e câmera multiespectral modelo RedEdge-M® (Micasense, Seattle, WA, EUA). Nesse experimento, foram utilizados os mapas de índices de vegetação NDVI (*Normalized Difference Vegetation Index*) (ROUSE et al., 1973) e NDRE (*Normalized Difference Red Edge Index*) (BARNES, et al., 2000) gerados a partir das imagens multiespectrais coletadas durante o período de pico vegetativo da cultura, nos meses de maio (FIGURA 3) e junho (FIGURA 4) de 2019. Apesar da maior popularidade do NDVI, que pode ser obtido também a partir de imagens com 10 m de resolução espacial, como as que são fornecidas gratuitamente pelo satélite Sentinel-2® (European Space Agency, Paris, França), o NDRE, por utilizar uma banda espectral que representa reflectâncias entre as bandas do vermelho e infravermelho próximo, tende a expressar melhor as regiões de transição entre plantas saudas e não saudas em uma área de produção agrícola.

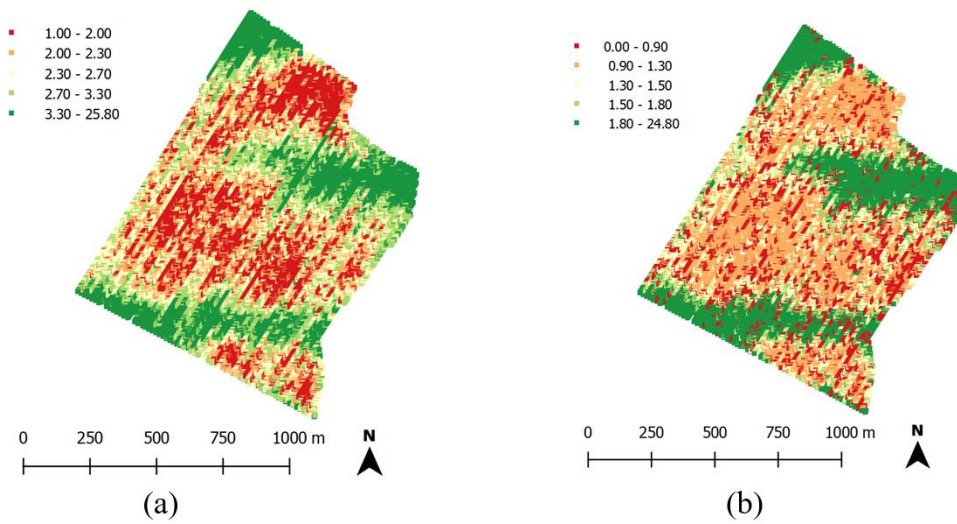


FIGURA 2. Mapas de condutividade elétrica aparente (CEa) do solo nas camadas (a) 0-30 cm e (b) 0-90 cm de profundidade, com valores em mS/m (Milisemens por metro).




FIGURA 3. Mapas de índices vegetativos: (a) NDVI e (b) NDRE, obtidos a partir de imagens multiespectrais coletadas por câmera a bordo de ARP, em maio de 2019.




FIGURA 4. Mapas de índices vegetativos: (a) NDVI e (b) NDRE, obtidos a partir de imagens multiespectrais coletadas por câmera a bordo de ARP, em junho de 2019.

A partir da análise visual de “manchas” presentes nos mapas das figuras 2 e 3(a) e do conhecimento de campo, a equipe técnica da propriedade responsável pela execução das atividades na área delineou, manualmente e com a ajuda de sistemas de informações geográficas (SIG), um mapa contendo cinco potenciais ZM para planejamento e execução de coletas de amostras de folhas, para análise nutricional; e identificação da presença de diferentes espécies de nematoides, sendo coletada uma amostra composta por ZM (FIGURA 5).

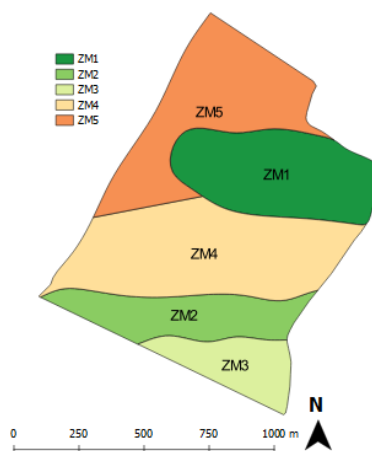


FIGURA 5. Mapa de ZM delineado manualmente a partir da observação de mapas de NDVI, CEa do solo e conhecimento de campo.

A colheita do algodão para esse talhão foi realizada em duas datas distintas, no início de agosto de 2019, por meio de colhedoras auto enfardadeiras modelo CP690® (John Deere, Moline, IL, EUA), todas elas dotadas de monitor de colheita, permitindo assim a geração de um mapa único de produtividade (FIGURA 6). Esse mapa consiste da fusão dos dados obtidos pelas diferentes colhedoras, normalizados pela média de produtividade geral do talhão. Comparando-se os mapas das figuras 5 e 6, é possível verificar, de maneira visual, que as ZM delimitadas manualmente retrataram bem as diferenças de produtividade da área, principalmente nos locais onde foram obtidos níveis mais altos (ZM1 e ZM2).

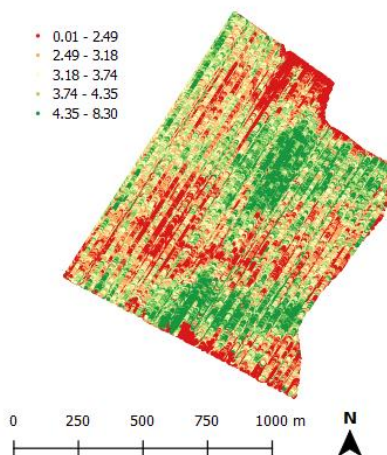


FIGURA 6. Mapa de produtividade do algodão da safra de 2019, com valores em toneladas por hectare.

De posse de todos os mapas exibidos nas figuras de 2 a 6, foi realizado um processo semiautomático de mineração dos dados, com o intuito de gerar mapas de potenciais ZM utilizando algoritmos de agrupamento, considerando como insumos as informações coletadas em campo e fornecidas pela equipe técnica da propriedade. A utilização desse tipo de algoritmo permite definir mapas de ZM mais precisos, considerando tanto a variabilidade espacial presente nos próprios dados, quanto informações relevantes e restritivas definidas pela equipe técnica. Para que os dados das figuras 2, 3, 4 e 6 pudessem ser utilizados como atributos de entrada para esses algoritmos, os mesmos tiveram que ser normalizados em uma grade espacial única. A grade utilizada possui resolução espacial de 10 m, e foi obtida a partir de imagens de sensoriamento remoto do satélite Sentinel-2. Como todos os mapas possuem alta densidade de pixels, o ajuste de grade se deu a partir de algoritmos de interpolação espacial determinísticos, reamostragem ou cálculo de médias de pontos internos a



cada pixel. Esse ajuste permitiu a obtenção de sete atributos distintos para análise por parte de algoritmos de agrupamento e posterior delineamento de potenciais ZM: CEa do solo nas profundidades de 0-30 e 0-90 cm; NDVI e NDRE nos meses de maio e junho de 2019; e produtividade da safra de 2019. Apesar de o delineamento de ZM realizado manualmente ser válido, o mesmo foi executado com base em apenas 3 atributos (CEa nas duas profundidades e NDVI no mês de maio de 2019). Conforme a quantidade de atributos aumenta, fica cada vez mais difícil o delineamento manual ser realizado e, portanto, cada vez mais necessário o uso de algoritmos de agrupamento para que o resultado tenha um menor erro e forneça mapas com ZM coesas e bem separadas entre si.

Boa parte dos trabalhos presentes na literatura que envolvem o delineamento de ZM a partir de análise de agrupamento utilizam algoritmos particionais para execução dessa tarefa, especialmente o *fuzzy c-means* (FCM) (BEZDEK et al., 1984; KITCHEN et al., 2005; LI et al., 2007; MORARI et al., 2009; CÓRDOBA et al., 2013; GAVIOLI et al., 2016). Apesar de considerar parte das incertezas que ocorrem no campo e possuir um custo computacional linear, esse algoritmo apresenta algumas desvantagens: necessidade de se determinar previamente a quantidade desejada de grupos (ou ZM, nesse contexto); inicialização aleatória, o que pode proporcionar o ajuste da sua função objetivo para um mínimo local (e não global); e o não-determinismo, muitas vezes provocado pela própria inicialização aleatória, que faz com que possam ser obtidos grupos distintos em diferentes execuções considerando o mesmo conjunto de dados e parâmetros de entrada. Para este trabalho, a análise de agrupamento foi realizada utilizando o algoritmo de agrupamento hierárquico aglomerativo de Ward (WARD JR, 1963), com a inclusão de restrições para possibilitar a implantação prática das ZM definidas. Apesar de possuir custo computacional quadrático, esse algoritmo é determinístico e fornece ao usuário uma árvore contendo uma série de possíveis agrupamentos, com diferentes quantidades de grupos, conhecida como dendrograma. A heurística de construção do dendrograma consiste na fusão dos dois grupos mais similares em cada nível. A medida de similaridade utilizada pelo algoritmo de Ward é baseada no aumento do erro quadrático médio, ou seja, em cada passo de construção do dendrograma, os grupos mais similares e, portanto, que deverão ser fundidos, são aqueles cuja fusão proporciona o menor aumento do erro quadrático médio (ou da variabilidade) do agrupamento como um todo. O dendrograma resultante proporciona ao usuário escolher a quantidade de grupos ou ZM que seja mais adequada para a sua aplicação, realizando cortes. A abordagem utilizada neste trabalho inclui restrições espaciais ao algoritmo de Ward, considerando a disposição das amostras no mapa, para reduzir a possibilidade do surgimento de ZMs muito pequenas e ineficazes na prática.

O processo de delineamento de ZM para este trabalho foi realizado com o objetivo de definir regiões distintas para a execução de experimentação *on-farm* para a safra do algodão de 2020. Esse tipo de experimentação consiste em definir, dentro da área total do talhão, ou, quando possível, dentro de cada ZM, parcelas virtuais de mesma área e que permitam a utilização de diferentes doses com repetições para aplicações com diferentes taxas de, por exemplo, população (taxa de sementes no plantio), adubação nitrogenada de cobertura e regulador de crescimento. Todos esses procedimentos devem ser realizados conforme o planejamento da própria propriedade, e com os equipamentos disponíveis. As variações de taxas e doses a serem aplicadas são previamente definidas, considerando como testemunha a dose padrão que já é utilizada na propriedade. Ao final da experimentação, é esperado o estabelecimento de recomendações (curvas de resposta) de dose de população e aplicação de insumos para a área de estudo, considerando a resposta fornecida pela cultura por meio da produtividade obtida.

**RESULTADOS E DISCUSSÃO:** Com os dados referentes aos sete atributos distribuídos na mesma grade, foi obtido um total de 10.701 amostras com resolução espacial de 10 m. Dados estatísticos referentes a esses atributos (TABELA 1) mostram que o coeficiente de variação do NDRE é em geral maior do que do NDVI tendo, portanto, maior potencial de explicar a resposta da cultura, como pode ser verificado pelos maiores coeficientes de determinação  $R^2$  obtidos, dentre os atributos correlacionados com a produtividade (coluna  $R^2$ -Prod) .

TABELA 1. Dados estatísticos referentes aos atributos utilizados para o delineamento de ZM por agrupamento de dados. Valores referentes aos dados ajustados em grade com 10 m de resolução espacial. A coluna  $R^2$ -Prod representa o coeficiente de determinação do atributo em questão com relação à produtividade.



Atributo	Data	Estatística				
		Média	Variância	Desvio Padrão	Coef. Variação	R <sup>2</sup> -Prod
CEa – 30 cm (mS/m)	Jan/2019	2,72	0,43	0,65	24,03	0,02
CEa – 90 cm (mS/m)	Jan/2019	0,55	0,35	0,59	106,56	0,18
NDVI-1	Mai/2019	0,87	0,006	0,08	8,87	0,20
NDRE-1	Mai/2019	0,47	0,002	0,05	10,12	0,35
NDVI-2	Jun/2019	0,85	0,005	0,07	8,64	0,11
NDRE-2	Jun/2019	0,37	0,005	0,07	19,90	0,26
Produtividade (ton/ha)	Ago/2019	3,40	0,40	0,63	18,68	-

Visando reduzir a possibilidade do surgimento de ZMs com área muito pequena e de difícil operacionalização na prática para a experimentação *on-farm*, foi utilizada uma metodologia de inicialização dos agrupamentos hierárquicos, conhecida como tesselação inicial (RUB e KRUSE, 2011). Esse procedimento leva em conta o princípio básico da geoestatística em considerar que amostras espacialmente próximas tendem a possuir características de solo e planta semelhantes. Sendo assim, o conjunto de 10.701 amostras foi dividido inicialmente em 200 grupos, a partir de algoritmo de agrupamento particional com inicialização não-aleatória (LLOYD, 1982) e utilizando como dados de entrada as coordenadas de latitude e longitude de cada amostra. Em seguida, utilizando como ponto de partida esse primeiro agrupamento gerado, a abordagem de agrupamento descrita na sessão anterior foi executada. Como resultado, foi gerado um dendrograma contendo outros 198 agrupamentos, onde a quantidade de grupos variou de 199 até 2. Para o contexto de delineamento de ZM, e considerando o mapa gerado de forma manual (FIGURA 5), decidiu-se pela realização de cortes no dendrograma resultante para os níveis de 2 a 5 grupos, gerando quatro mapas de ZM distintos. Em seguida, foi realizada uma análise utilizando o critério de validação interna da largura de silhueta (ROUSSEEUW, 1987), como uma tentativa de identificar qual desses mapas e, conseqüentemente, qual a quantidade de ZMs seria a mais indicada, considerando a coesão e a separação dos grupos gerados (FIGURA 7).

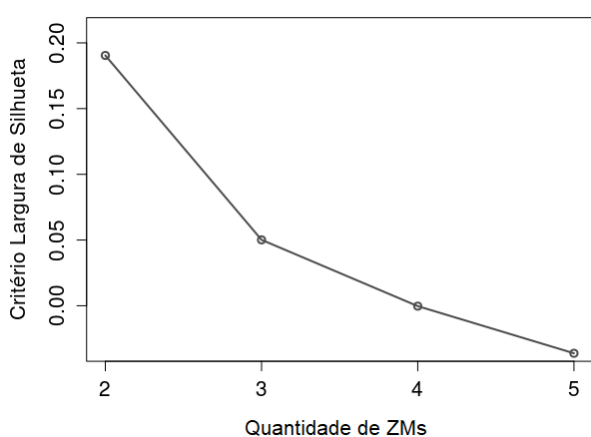


FIGURA 7. Critério da largura de silhueta aplicado nos 4 agrupamentos distintos gerados (de 2 a 5 ZMs).

Da maneira como os resultados estão exibidos na FIGURA 7, o critério da largura de silhueta permite uma análise relativa entre as quantidades de ZM pretendidas. No caso desse critério, os maiores índices indicam uma possibilidade maior de grupos mais coesos e bem separados e, portanto, se levarmos em consideração apenas esse resultado, o mapa contendo 2 ZM seria o mais indicado. Complementarmente, o valor da largura de silhueta para o mapa com 5 ZM delineado manualmente foi de -0,04 e, portanto, muito próximo ao valor (também negativo) obtido pelo mapa de 5 ZM delineado pela abordagem de agrupamento. Valores negativos para esse critério indicam que pode existir uma grande sobreposição de grupos, e que amostras alocadas em um determinado grupo poderiam proporcionar melhores resultados se tivessem sido alocadas em grupos

vizinhos. Adicionalmente, e até como forma de comprovar o resultado fornecido por esse critério, foram obtidos os valores médios de cada atributo em cada ZM, considerando os quatro mapas gerados pela abordagem de agrupamento e o mapa contendo 5 ZM, gerado manualmente (TABELA 2).

TABELA 2. Valores médios de cada atributo para cada ZM nos quatro mapas gerados por abordagem computacional de agrupamento de dados e no mapa gerado manualmente.

Atributo	Agrupamentos (valores médios)																			
	2 ZM		3 ZM			4 ZM				5 ZM				5 ZM - Manual						
	1	2	1	2	3	1	2	3	4	1	2	3	4	5	1	2	3	4	5	
CEa-30	2,39	3,03	2,39	3,11	2,92	2,39	3,11	2,91	2,36	2,38	3,11	2,92	2,40	2,36	3,14	3,28	2,51	2,35	2,61	
CEa-90	0,36	0,72	0,36	0,71	0,73	0,35	0,72	0,73	0,55	0,35	0,72	0,72	0,33	0,56	0,81	0,74	0,33	0,27	0,67	
NDVI-1	0,84	0,89	0,85	0,89	0,89	0,85	0,89	0,89	0,80	0,84	0,89	0,89	0,87	0,80	0,89	0,89	0,81	0,86	0,86	
NDRE-1	0,45	0,50	0,45	0,50	0,49	0,46	0,50	0,49	0,44	0,45	0,50	0,49	0,47	0,44	0,50	0,50	0,43	0,46	0,47	
NDVI-2	0,82	0,88	0,82	0,88	0,87	0,82	0,88	0,87	0,77	0,82	0,88	0,87	0,84	0,77	0,88	0,88	0,79	0,84	0,84	
NDRE-2	0,33	0,40	0,33	0,40	0,40	0,33	0,40	0,40	0,28	0,33	0,40	0,40	0,34	0,28	0,41	0,41	0,28	0,34	0,37	
Prod.	2,98	3,78	2,98	4,02	3,47	3,02	4,02	3,47	2,40	2,98	4,02	3,47	3,15	2,40	3,89	3,92	3,03	3,21	3,06	

Na TABELA 2, é possível observar que o mapa com 2 ZM mostra valores médios bem distintos entre as duas ZM considerando todos os atributos e, principalmente, para os valores de produtividade. Já para o mapa com 3 ZM, é possível observar que as médias obtidas para as ZMs 2 e 3 são relativamente próximas, não sendo de interesse prático essa separação. Por conta disso, essas 2 ZM foram fundidas pela abordagem computacional durante a formação do mapa contendo 2 ZM. Para os mapas contendo 4 e 5 ZM, algumas ZMs mostraram valores médios de produtividade também muito próximos e, considerando os outros atributos, até valores coincidentes em alguns casos. Essa proximidade de valores médios dificulta a separação dos grupos por parte da abordagem de agrupamento, gerando índices mais baixos para o critério da largura de silhueta, conforme a quantidade de ZMs aumenta. [CV1] Essa dificuldade também pode ser observada para o mapa de ZM delineado manualmente, principalmente entre as ZMs 1 e 2 e ZMs 4 e 5. A partir dessa análise complementar, entende-se que o mapa contendo 2 ZM é a melhor alternativa, dentre as que foram apresentadas, para a implementação da experimentação *on-farm* para essa área. A análise visual dos mapas de ZM obtidos (FIGURA 8) também é importante nesse contexto, para que seja avaliada a potencialidade de cada um em estabelecer ZMs capazes de atender aos requisitos da experimentação *on-farm*.

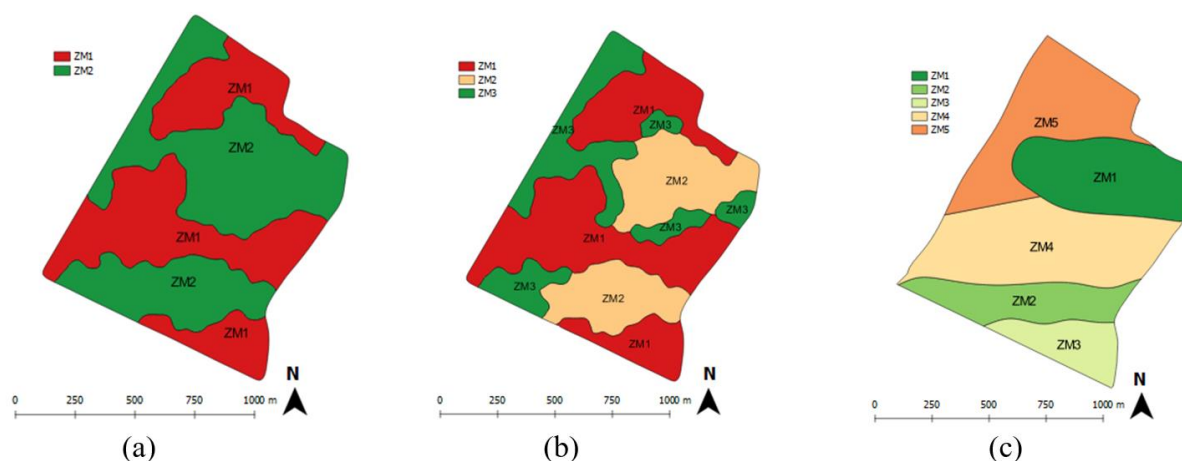


FIGURA 8. Mapas de ZM para o planejamento de experimentação *on-farm* contendo (a) 2 ZM e (b) 3 ZM,

geradas a partir da abordagem de agrupamento e os sete atributos da TABELA 1; e (c) 5 ZM, geradas manualmente pelo usuário, considerando os atributos CEa-30, CEa-90 e NDVI-1 da TABELA 1.

O mapa contendo 3 ZM (FIGURA 8b) mostra que a ZM 3 foi particionada em 5 regiões espacialmente disjuntas. A menor dessas regiões possui cerca de 1,5 ha de área, o que inviabilizaria a experimentação *on-farm* pretendida. Na prática, em uma experimentação desse tipo é importante distribuir, em cada ZM, parcelas virtuais com pelo menos três diferentes taxas de aplicação de insumos com repetições. Desse modo, ZMs ou partições de ZMs muito pequenas devem ser evitadas. Ainda com relação a esse mesmo mapa, deve ser considerada também a proximidade de valores médios para os atributos entre as ZMs 2 e 3, conforme já exemplificado na TABELA 2, o que proporcionou a fusão dessas duas ZM por parte da abordagem de agrupamento utilizada, resultando no mapa da FIGURA 8a. É possível verificar também semelhanças entre os mapas das figuras 8a e 8c. Considerando os dados de produtividade da TABELA 2, as ZMs 3, 4 e 5 e as ZMs 1 e 2 do mapa da FIGURA 8c poderiam ser fundidas em apenas duas ZMs, renomeadas, respectivamente, como ZM1 e ZM2. Nesse caso, a área da nova ZM1 (composta pelas ZMs 3,4 e 5 da Figura 8c) representaria cerca de 92% da área total da ZM1 do mapa da Figura 8(a); e a área da nova ZM2 (composta pelas ZMs 1 e 2 do mapa da Figura 8c) representaria cerca de 60% da área da ZM2 do mapa da FIGURA 8a. Essas diferenças se devem principalmente aos ajustes automáticos realizados pela abordagem de agrupamento e a utilização de outros cinco atributos adicionais em relação aos que foram utilizados para o delineamento manual. Considerando o mapa de 2 ZM exibido na FIGURA 8a, a experimentação *on-farm* para duas intervenções com aplicação de insumos de cobertura foram então planejadas para a safra do algodão de 2020 (FIGURA 9).

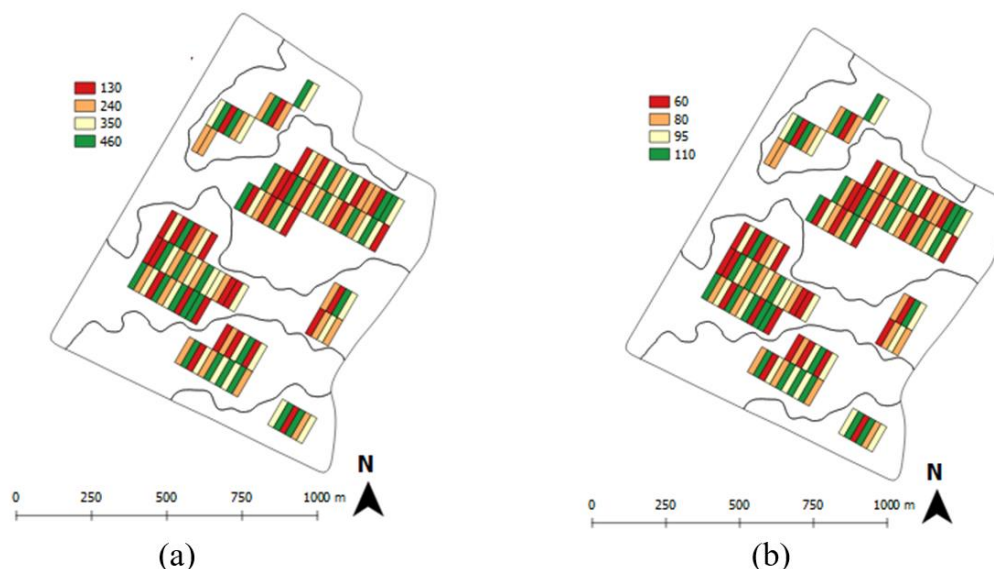


FIGURA 9. Planejamento de experimentação *on-farm* considerando ZMs e a aplicação de adubação de cobertura de (a) : (a) composto NPK (nitrogênio, fósforo e potássio) (a); e (b) (b) ureia (b). Valores em kg/ha.

Para ambas as intervenções, foram definidos quatro níveis de taxas de aplicação, com quatro repetições distribuídas em cada ZM, totalizando 128 parcelas de aproximadamente 0,22 ha cada. O objetivo principal dessas intervenções é de identificar, para cada ZM, a resposta da cultura com relação aos diferentes níveis de insumo aplicados e, conseqüentemente, gerar recomendações de adubação por ZM, inicialmente para a área em específico, mas que, posteriormente, possa servir para outras áreas com características semelhantes. Em resumo, este trabalho mostrou que é possível delinear bons mapas de ZM manualmente, principalmente quando se tem uma área onde a variabilidade espacial tanto do solo quanto da cultura é bastante evidente. Entretanto, quando a quantidade de atributos aumenta, mesmo com essas evidências de localização, a tarefa se torna complexa e praticamente impossível de ser realizada sem o auxílio de algoritmos computacionais. No caso dessa área, a utilização de mais atributos adicionais e da abordagem de agrupamento computacional possibilitaram a obtenção de ZMs mais coesas e bem separadas, eliminando questões subjetivas que são naturais de uma análise manual.

**CONCLUSÃO:** Este trabalho descreveu o processo de delineamento de ZM realizado em um talhão experimental de produção de algodão localizado em Sapezal-MT. Esse delineamento teve como objetivo

auxiliar na estratégia de planejamento de uma experimentação *on-farm* para aplicação de adubação nitrogenada de cobertura em diferentes datas. Como trabalho futuro, será realizado o acompanhamento do crescimento da cultura e os efeitos causados pelas diferentes doses de aplicação de NPK e ureia, realizados de maneira equivalente nas 2 ZM identificadas. Para esse acompanhamento, serão avaliados, dentre outros atributos, imagens multiespectrais de sensoriamento remoto e suborbital; características físicas e de pedologia do solo; regiões com infestações de nematoides; e a produtividade da safra de 2020. O principal objetivo dessa análise é que, ao final, sejam obtidas doses recomendadas de NPK e ureia para as 2 ZM utilizadas, visando o manejo sítio-específico desse talhão nas safras futuras utilizando as ferramentas e os conhecimentos gerados pela AP.

#### **AGRADECIMENTOS:**

Agradecemos às equipes técnicas e de gestão do Instituto Matogrossense do Algodão (IMAmt), em nome dos engenheiros agrônomos Amandio Pires Junior e Márcio de Souza; do grupo Amaggi, em nome do administrador Sergio das Chagas e da engenheira agrícola e ambiental Karinna Pinheiro de Oliveira; e da Embrapa Instrumentação, em nome do engenheiro elétrico e pesquisador Ladislau Marcelino Rabello, pelo suporte operacional e disponibilização dos dados coletados. Agradecemos também ao prof. Ricardo Ciferri, do DC/UFSCar, pelo apoio técnico-científico.

#### **REFERÊNCIAS**

ABRAPA. **Associação Brasileira dos Produtores de Algodão**. Disponível em: <<https://www.abrapa.com.br>>. Acesso em: 06 de abril de 2020.

BARNES, E. M. et al. Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data. In: **Proceedings of the Fifth International Conference on Precision Agriculture, Bloomington, MN, USA. 2000.**

BERNARDI, A. C. de C. et al. (Ed.). **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014. 596 p.

BEZDEK, J. C.; EHRLICH, R.; FULL, W. FCM: The fuzzy c-means clustering algorithm. **Computers & Geosciences**, v. 10, n. 2-3, p. 191-203, 1984.

BULLOCK, D.S. et al. The data-intensive farm management project: Changing agronomic research through On-farm precision experimentation. **Agronomy Journal**, v. 111, n. 6, p. 2736-2746, 2019.

CONAB. **Companhia Nacional de Abastecimento**. Boletim da Safra de Grãos. Disponível em: <<https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos>>. Acesso em: 03 de abril de 2020.

CÓRDOBA, M. al. Subfield management class delineation using cluster analysis from spatial principal components of soil variables. **Computers and electronics in agriculture**, v. 97, p. 6-14, 2013.

DOERGE, T. A. **Management Zones Concepts**. Norcross, 1999.

FUNDAÇÃO MT. **Produtores de algodão enfrentam cenário desafiador com preços baixos e custo de produção elevado**. Disponível em <<https://www.fundacaomt.com.br>>. Acesso em: 03 de abril de 2020.

GAVIOLI, A. et al. Optimization of management zone delineation by using spatial principal components. **Computers and Electronics in Agriculture**, v. 127, p. 302-310, 2016.

KITCHEN, N. R. et al. Delineating productivity zones on claypan soil fields using apparent soil electrical conductivity. **Computers and Electronics in Agriculture**, v. 46, n. 1-3, p. 285-308, 2005.

LI, Yan et al. Delineation of site-specific management zones using fuzzy clustering analysis in a coastal saline land. **Computers and Electronics in Agriculture**, v. 56, n. 2, p. 174-186, 2007.

LLOYD, S. Least squares quantization in PCM. **IEEE transactions on information theory**, v. 28, n. 2, p. 129-137, 1982.

MOLIN, J. P.; AMARAL, L.R.; COLAÇO, A. **Agricultura de precisão**. Oficina de Textos, 2015.

MORARI, F.; CASTRIGNANÒ, A.; PAGLIARIN, C. Application of multivariate geostatistics in delineating management zones within a gravelly vineyard using geo-electrical sensors. **Computers and Electronics in Agriculture**, v. 68, n. 1, p. 97-107, 2009.

ROUSE, J.W. et al. Monitoring vegetation systems in the Great Plains with ERTS. **NASA special publication**, v. 351, p. 309, 1974.

ROUSSEEUW, Peter J. Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. **Journal of computational and applied mathematics**, v. 20, p. 53-65, 1987.

RUB, G.; KRUSE, R. Exploratory hierarchical clustering for management zone delineation in precision agriculture. In: **Industrial Conference on Data Mining**. Springer, Berlin, Heidelberg, 2011. p. 161-173.

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.

WARD JR, J. H. Hierarchical grouping to optimize an objective function. **Journal of the American statistical association**, v. 58, n. 301, p. 236-244, 1963.

# TÉCNICAS DE MACHINE LEARNING NA PREDIÇÃO DA PRODUTIVIDADE DE ALGODÃO EM CAROÇO UTILIZANDO SENSORIAMENTO REMOTO POR SATÉLITE

Renan Francisco Rimoldi Tavanti<sup>1</sup>; Douglas Pedrini<sup>2</sup>; Guilherme Morais<sup>2</sup>; Anderson Cândido da Silva<sup>3</sup>; Adriano Morel<sup>4</sup>

<sup>1</sup>Eng. Agrônomo, Coordenador de Agricultura Digital - Departamento de Planejamento Agrícola, SLC Agrícola. renan.tavanti@slcagricola.com.br / (18) 9 9826-1001; <sup>2</sup>Eng. Agrônomo, Analista de Agricultura de Precisão - Departamento de Planejamento Agrícola, SLC Agrícola; <sup>3</sup>Eng. Agrônomo, Especialista de Planejamento e Controle em Agricultura Digital - Departamento de Planejamento Agrícola, SLC Agrícola; <sup>4</sup>Eng. Agrícola, Analista de Planejamento e Controle em Agricultura Digital - Departamento de Planejamento Agrícola, SLC Agrícola

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** O objetivo desse estudo foi propor um fluxo de processos em *machine learning* (ML) para auxiliar nas estimativas de produtividade do algodão em caroço, a partir de índices de vegetação e teor de argila do solo, utilizando o modelo Random Forest (RF) e técnicas de redução de dimensionalidade e classificação não-supervisionada. O estudo foi realizado na safra 2020/21 em sete lavouras de produção comercial de algodão sequeiro do Estado de Mato Grosso. Imagens do satélite Sentinel-2 foram obtidas durante o período de condução da cultura, bem como dados de teor de argila e produtividade. Uma grade amostral de 20 × 20 m foi criada para cada lavoura, para extrair os valores dos atributos mencionados. Cinco foram separadas para treinamento (70% dos dados) e teste (30%) do modelo RF. As outras duas foram destinadas à validação. Como parte do fluxo de processos de ML, foram realizadas análises de correlação de Spearman, classificação fuzzy k-means e análise de componentes principais, para entender a relação entre os índices de vegetação, nas diferentes épocas, e a produtividade de algodão, bem como sintetizar/padronizar o número de variáveis de entrada no modelo. O modelo RF foi ajustado aos dados de treinamento com ótima precisão ( $R^2$  ajustado > 0,8) e baixos desvios, significativo a 0,01 de probabilidade. Os resultados do teste e validação indicaram precisão nas estimativas mostrando-se um método promissor para futuros estudos.

**PALAVRAS-CHAVE:** Índices de vegetação; Random Forest; Análise de Componentes Principais

## MACHINE LEARNING TECHNIQUES TO PREDICT COTTON YIELD USING SATELLITE REMOTE SENSING

**ABSTRACT:** The objective of this study was to propose a process flow in machine learning (ML) to assist in the estimation of cotton yield, from vegetation indices and soil clay content, using the Random Forest (RF) model and techniques of dimensionality reduction and unsupervised classification. The study was carried out in the 2020/21 agricultural year in six commercial dryland cotton plots in the state of Mato Grosso. Sentinel-2 satellite images were obtained during the crop conduction period, as well as clay content and yield data. A 20 × 20 m sampling grid was created for each crop to extract the values of the mentioned attributes. Five were separated for training (70% of the data) and testing (30%) of the RF model. The other two were intended for validation. As part of the ML process flow, Spearman correlation analysis, fuzzy k-means classification and principal component analysis were performed to understand the relationship between vegetation indices, at different times, and cotton yield, as well as synthesize/standardize the number of input variables in the model. The RF model was fitted to the training data with great precision (adjusted  $R^2 > 0.8$ ) and low deviations, significant at 0.01 probability. The results of the test and validation indicated precision in the estimates, proving to be a promising method for future studies.

**KEYWORDS:** Vegetation Indices; Random Forest; Principal Component Analysis

**INTRODUÇÃO:** Imagens de satélites são ferramentas digitais úteis e escaláveis para o monitoramento das culturas agrícolas. As faixas do espectro eletromagnético correspondentes às bandas do vermelho (~630-690 nm), verde (~520-600 nm), azul (~450-520 nm) e infravermelho próximo (~760-900 nm), têm sido

amplamente utilizadas para calcular índices de vegetação (IV) e monitorar as mudanças que ocorrem na cobertura vegetal (Parente et al., 2019; Plant et al., 2001). Esses índices têm aplicações em análises de produção de biomassa, índice de área foliar, alterações causadas por estresses bióticos (como lesões por pragas e doenças) e abióticos (estresse hídrico, temperatura e nutricional; principalmente deficiência de N) (Gerik et al., 1998; Xue & Su, 2017). Isso é possível devido às respostas fisiológicas que ocorrem nas plantas, modificando diretamente o comportamento espectral do dossel (reflectância).

Acompanhando o avanço da agricultura digital, o aprendizado de máquinas, também conhecido como *machine learning* (ML), e *big data* possibilitaram a criação de modelos de predição baseados em dados de satélites. Esses modelos permitem a visualização de tendências na produção agrícola e outros indicadores relacionados à saúde das lavouras. Com isso, possibilitam o usuário tomar decisões antecipadas sobre a gestão das lavouras, ainda em pleno desenvolvimento a campo. Além das bandas espectrais utilizadas como variáveis de entrada nesses modelos, IVs também são utilizados para essa finalidade, como por exemplo: *Normalized Difference Vegetation Index* (NDVI), *MERIS terrestrial chlorophyll index* (MTCI), *Normalized Difference Water Index* (NDWI) e *Enhanced Vegetation Index* (EVI) (Hawry?o et al., 2018).

Para culturas como a soja e o algodão, ainda são incipientes modelos acurados nas estimativas de produtividade. Isso ocorre devido às características intrínsecas dessas culturas, que nem sempre correlacionam o rendimento de grãos ou fibras com a produção de biomassa e a resposta espectral do dossel (Jackson & Ezra, 1985; Zhao et al., 2007). Tendo em vista reduzir os erros das estimativas e melhorar a performance dos modelos, técnicas de ML e a utilização de variáveis auxiliares podem ser úteis para essa finalidade. Sabe-se que o teor de argila atua como um condicionador da umidade e da fertilidade do solo. Em áreas argilosas observa-se maior estabilidade da produção quando comparado às áreas arenosas, que estiveram submetidas à algum estresse abiótico (principalmente hídrico). Nesse sentido, essa variável pode ser utilizada como um *background*, para auxiliar nas estimativas junto aos IVs. Dentre as técnicas de ML mais utilizadas, a classificação supervisionada/ não-supervisionada, redução de dimensionalidade e análises de correlação espacial, também podem auxiliar no treinamento dos modelos, tendo em vista a criação de “filtros” que sintetizam as informações e delimitam regiões comuns entre as variáveis de entrada por meio da classificação.

O objetivo desse estudo foi propor um fluxo de processos em ML para auxiliar nas estimativas de produtividade do algodão em caroço, a partir de IVs e teor de argila do solo, utilizando o modelo Random Forest e técnicas de redução de dimensionalidade e classificação não-supervisionada.

**MATERIAIS E MÉTODOS:** O estudo foi realizado durante a safra 2020/21 em cinco fazendas de produção comercial de algodão sequeiro do Estado de Mato Grosso (MT). Foram selecionadas seis lavouras para estudo: PH102 (13°59'37"S; 55°27'25,7"O; 536 m), PR106 (13°59'96"S; 58°52'13,8"O; 650 m), PR114 (13°56'55,3"S; 58°50'10,2"O; 636 m), PR122 (13°55'24,1"S; 58°49'19,2"O; 626 m), PG41 (13°59'48,8"S; 57°24'35,7"O; 598 m), PW219 (13°51'50,2"S; 57°36'22,1"O; 576 m) e PX113 (11°12'42,3"S; 56°21'14,7"O; 421 m). O clima das regiões, de acordo com a classificação de Köppen, é do tipo Aw (tropical úmido), caracterizado por verão chuvoso e inverno seco. A temperatura média e precipitação acumulada anual nessas regiões variam entre 24 e 26 °C e 1.800 e 2.200 mm, respectivamente.

Os dados de teor de argila das lavouras foram obtidos a partir da prévia amostragem de solo em grades de 1:3 ha, posteriormente interpolados por krigagem ordinária após ajuste de semivariogramas (Figura 1A). Os dados de produtividade foram coletados de colhedoras JD CP690 Cotton Picker e posteriormente analisados quanto a necessidade de correções, filtragem e remoção de outliers, seguindo metodologia descrita por Spekken et al. (2013). Em seguida foram interpolados seguindo critérios mencionados anteriormente. Imagens do satélite Sentinel-2A foram obtidas durante o período de condução do algodão. Foram selecionadas imagens livres de nuvens e que apresentassem a área total das lavouras em uma única imagem. IVs foram calculados para todas as épocas e lavouras. Calculou-se os índices NDVI, EVI, MTCI, NDWI, *Near-infrared Reflectance of Vegetation* (NIRV), *Carotenoid Reflectance Index* (CRI-1 e 2), *Normalized Difference Infrared Index Band 11* (NDII) e *Chlorophyll Index Green* (CI), conforme descritos por Hawry?o et al. (2018) (Figura 1B).

Uma grade amostral de resolução 20 × 20 m foi criada para cada lavoura de estudo, para extrair os valores espectrais dos IVs, juntamente com os valores dos mapas de teor de argila e produtividade de algodão em caroço. Um buffer de -100 m foi realizado no polígono de cada lavoura, para garantir que os valores obtidos



não tenham influência de carreadores, solo exposto ou qualquer efeito de bordadura. Diante disso, a média de pontos por lavoura ficou em 2.841.

Após a organização das informações nas grades de coleta, foi realizada a análise exploratória e teste de normalidade de Shapiro-Wilk para a produtividade de algodão e teor de argila do solo. A correlação de Spearman foi realizada para entender a relação entre os IVs, nas diferentes épocas, e a produtividade de algodão (Figura 1C). Essa análise foi realizada como uma triagem inicial para separar os IVs com coeficientes correlação (R) moderada, ou seja,  $R > 0,4$  e  $R < -0,4$ . Em seguida, os IVs selecionados na análise de Spearman foram submetidos à padronização, transformando-os em desvios padrão que variam de 1 a -1 (Pedregosa et al., 2011). Com objetivo de uniformizar o número de variáveis de entrada no modelo de predição, procedeu-se a classificação não-supervisionada, utilizando algoritmo de clusterização fuzzy k-means (k clusters = 10; definidos pela soma dos quadrados intra cluster), e a redução de dimensionalidade, utilizando análise de componentes principais (PCA) (Figura 1D). Os produtos obtidos dessas abordagens multivariadas são os mapas de cluster e os três primeiros componentes principais (PC) obtidos da PCA (PC1, PC2 e PC3; selecionados por reter a maior % de variação do conjunto de dados), que descrevem o comportamento entre as variáveis (Figura 1E). Independentemente do número de IVs obtidos em cada época e lavoura, foi possível a criação dessas novas variáveis sintéticas que foram utilizadas como predictoras (variáveis de entrada no modelo).

Após gerados os mapas de cluster e PCs, avaliou-se a correspondência dos scores com regiões de alta e baixa produtividade de algodão. Em situações que os scores dos PCs ou clusters estiveram invertidos (valores máximos correspondendo à regiões de baixa produtividade, ou vice-versa), aplicou-se o fator de multiplicação (-1). Também se realizou a padronização dos scores dos PCs para o intervalo entre -1 e 1, utilizando a função tangente hiperbólica:

$$\tan.h = \frac{\text{sen}.h(x)}{\text{cos}.h(x)} \quad (1)$$

em que  $\tan.h$  corresponde à tangente hiperbólica,  $\text{sen}.h$  ao seno hiperbólico,  $\text{cos}.h$  ao cosseno hiperbólico.

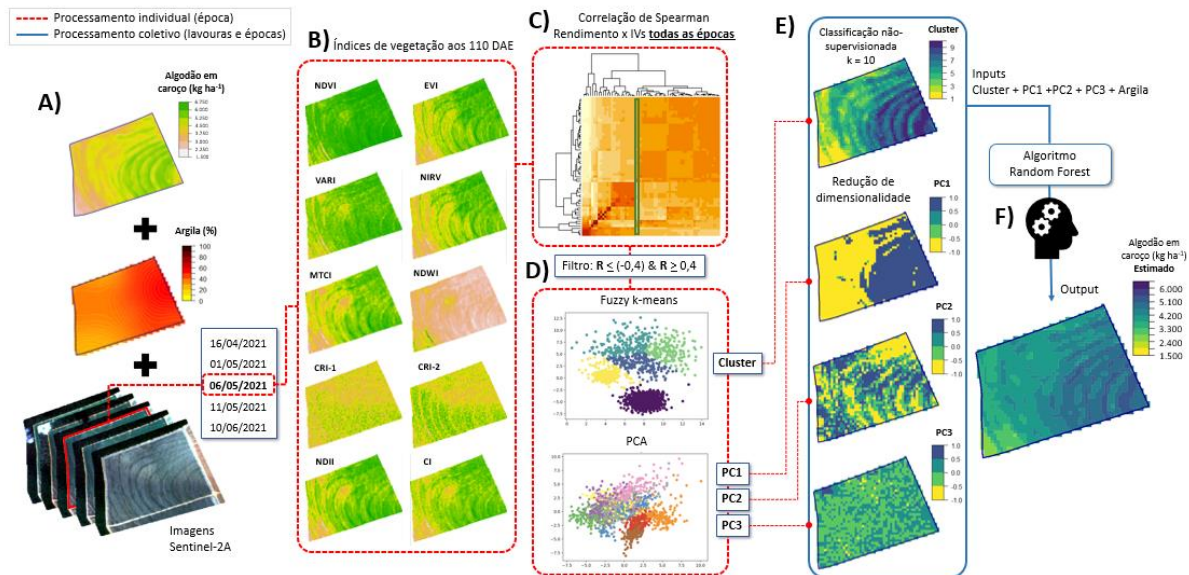


Figura 1

FIGURA 1. Fluxo de processamento de dados (no exemplo lavoura PH102 aos 110 DAE) para aquisição de mapas de cluster e componentes principais, utilizados como dados de treinamento do modelo Random Forest. A) Dados de entrada; B) Índices de vegetação (IV) calculados para época 110 DAE; C) Matriz de correlação de Spearman para seleção de IV correlacionados à produtividade observada; D) Classificação não-supervisionada fuzzy k-means (k clusters = 10) e análise de componentes principais (PCA) separando os três primeiros componentes; E) Input de dados para treinamento do modelo Random Forest; F) Output (produtividade estimada) para cálculo de métricas de qualidade do modelo. **Data processing flow (in the example PH102 plot – 110 DAE) for the acquisition of cluster and principal components maps, used as training data for the Random Forest model. A) Input data; B) Vegetation indices (IV) calculated for the**

**110 DAE season; C) Spearman correlation matrix for selection of VI correlated with observed yield; D) Unsupervised classification fuzzy k-means (k clusters = 10) and principal component analysis (PCA) separating the first three components; E) Data input for training the Random Forest model; F) Output (estimated yield) for calculating model quality metrics.**

Random Forest é um modelo de ML amplamente utilizado para estimar atributos das culturas agrícolas. Trata problemas comumente encontrados em dados de treinamento, como por exemplo a colinearidade, e captura comportamentos não-lineares entre variáveis, construindo uma infinidade de árvores de decisão. Nesse sentido, quatro lavouras (PH102, PR106, PR114, PG41 e PW219) foram separadas para treinamento (70% dos dados) e teste (30% dos dados) do modelo (Figura 1F). As demais lavouras (PR122 e PX113) foram separadas para posterior validação do modelo. As avaliações de desempenho do modelo foram realizadas pelos cálculos de raiz quadrada do erro médio (RMSE), erro médio absoluto (MAE) e coeficiente de determinação ajustado ( $R^2$  ajustado). Gráficos de validação cruzada foram construídos para todos os conjuntos de dados, para avaliação da produtividade observada  $\times$  predita pelo modelo. Todas as análises estatísticas foram realizadas em ambiente R versão 4.1.2 (R Core Team, 2021), utilizando os pacotes “sf”, “raster”, “caret”, “rgdal” e “gstat”.

**RESULTADOS E DISCUSSÃO:** Os resultados da análise descritiva indicaram elevada amplitude dos teores de argila, entre 21 e 50%, para as lavouras PH102 e PW219 (Tabela 1). Essa variabilidade pôde ser confirmada pelos desvios padrão (DP), entre 7,47 e 4,79%, respectivamente. As médias dessas lavouras caracterizaram solos de textura argilosa ( $> 35$  e  $< 60\%$ ), no entanto, pelos valores mínimos observou-se a presença de regiões classificadas como textura média ( $> 15$  e  $< 35\%$ ). Quanto as demais lavouras (PR106, PR114, PG41, PR122 e PX113), essas apresentaram teores de argila entre 55 e 75%, indicando baixa amplitude entre valores máximos e mínimos. Observou-se também valores de mediana próximas às médias (66%) e baixos DPs (entre 0,84 e 2,90%), confirmando a baixa variabilidade dos teores de argila para essas áreas. Sabe-se que a textura do solo pode condicionar a agregação, a porosidade e a densidade do solo, inferindo diretamente na disponibilidade de água às plantas (Bonetti et al., 2017). Neste caso, assume-se que o teor de argila pode ser um fator preponderante na variabilidade espacial da produtividade do algodão. Além disso, esse atributo mostra-se como uma variável auxiliar potencial na construção de modelos de ML para estimativas da produtividade de algodão.

TABELA 1. Análise descritiva e teste de normalidade da produtividade de algodão em caroço e do teor de argila do solo. **Descriptive analysis and normality test of cotton yield and soil clay content.**

Lavoura	Teor de argila (%)						Produtividade algodão em caroço (kg ha <sup>-1</sup> )					
	Mínimo	Máximo	Média	Mediana	DP <sup>1</sup>	S-W <sup>2</sup>	Mínimo	Máximo	Média	Mediana	DP <sup>1</sup>	S-W <sup>2</sup>
Dados de treinamento												
PH102	21	50	36	34	7,47	0,963*	2.445	5.355	4.260	4.230	559	0,979*
PR106	63	71	67	67	1,88	0,982*	2.580	5.085	4.185	4.215	286	0,981*
PR114	67	71	69	69	0,84	0,986*	2.850	5.310	4.110	4.110	279	0,997*
PG41	63	72	68	67	2,10	0,980*	3.630	4.755	4.170	4.155	174	0,994*
PW219	28	46	40	42	4,79	0,892*	2.385	4.260	3.435	3.450	293	0,998*
Dados de validação												
PR122	62	75	67	67	2,90	0,973*	3.930	6.510	5.550	5.610	342	0,961*
PX113	55	63	60	61	2,40	0,879*	4.305	6.090	5.400	5.430	273	0,984*

<sup>1</sup> DP: desvio padrão; <sup>2</sup> S-W: W calculado do teste de Shapiro-Wilk, \* indica significativo à 0,05 de probabilidade.

Os resultados da produtividade de algodão indicaram médias próximas de 4.275 kg ha<sup>-1</sup>, similar a média nacional da safra 2020/21 que foi de 4.279 kg ha<sup>-1</sup> (CONAB, 2021), considerando um rendimento de 40% (Tabela 1). Observou-se a maior amplitude de valores para as lavouras PH102 e PR122, entre 2.445 e 6.510 kg ha<sup>-1</sup>, considerando a mínima e máxima produtividade, bem como os maiores valores de DP (559 e 342 kg ha<sup>-1</sup>, respectivamente). As demais lavouras também apresentam elevada variabilidade, no entanto com DPs entre 174 e 293 kg ha<sup>-1</sup>. O teste de Shapiro-Wilk rejeitou a hipótese de normalidade dos dados de produtividade de algodão e teor de argila para todas as lavouras analisadas. Embora o teste tenha sido significativo para esses atributos, indicando desvios na normalidade, considerou-se que esses dados apresentavam uma distribuição tendendo à normalidade. Isso pode ser justificado pela proximidade entre a média e a mediana desses atributos (Tabela 1).

O modelo RF foi ajustado aos dados de treinamento com ótima precisão (R<sup>2</sup> ajustado: 0,805; RMSE: 176 kg ha<sup>-1</sup> e MAE: 123 kg ha<sup>-1</sup>), significativo a 0,01 de probabilidade (Figura 2A). As 11.341 amostras (70% do conjunto de dados) usadas para treinamento, foram suficientes para ajustar o modelo nas condições do estudo. Além disso, o coeficiente de correlação obtido (R = 0,89) indicou forte relação entre os atributos preditores e a produtividade de algodão. Pelo cálculo da importância relativa de variáveis, observou-se que o teor de argila foi o atributo de maior relevância para o modelo, seguido pelo PC1, cluster e PC2, com 76%, 50% e 8% de relevância, respectivamente.

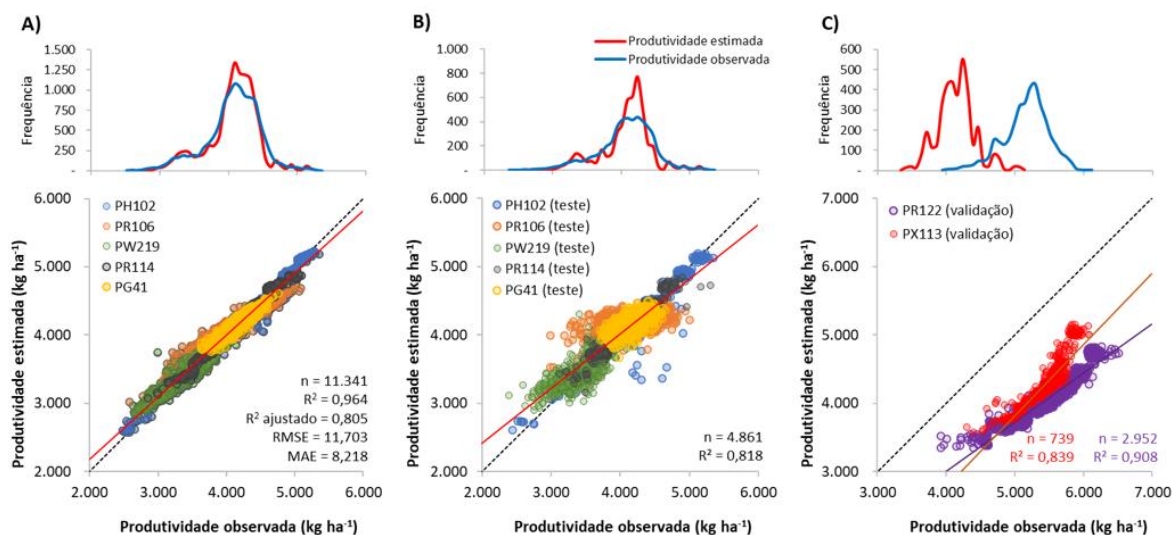


Figura 2

FIGURA 2. Valores de produtividade de algodão em caroço (kg ha<sup>-1</sup>) estimados pelo modelo Random Forest em função da produtividade observada. A) conjunto de dados de treinamento (70% das observações); B) conjunto de dados de teste (30% das observações) e; C) conjunto de dados de validação (todas observações das lavouras PR122 e PX113, não utilizadas no treinamento do modelo RF). **Cotton yield (kg ha<sup>-1</sup>) estimated by the Random Forest model as a function of observed yield. A) training dataset (70% of observations); B) test dataset (30% of observations) and; C) validation dataset (all observations of PR122 and PX113 plots, not used in RF model training).**

As estimativas da produtividade na base de dados de teste (4.861 amostras; 30% do conjunto de dados) reafirmam a qualidade do modelo proposto. Para essa base obteve-se um R<sup>2</sup> de 0,82 e um R de 0,90 entre os valores estimados e observados, que se aproximaram de uma linha de 1:1 (Figura 2B). No gráfico de dispersão (validação-cruzada), observou-se maiores desvios na lavoura PR106, devido a uma clara tendência de superestimar produtividades abaixo de 3.900 kg ha<sup>-1</sup> e subestimar acima de 4.350 kg ha<sup>-1</sup>. Observou-se também um aumento da frequência de valores estimados próximos da mediana (4.125 kg ha<sup>-1</sup>), no intervalo entre 3.750 e 4.500 kg ha<sup>-1</sup>, conforme indicado no respectivo histograma. Isso indica que valores máximos e mínimos de produtividade foram estimados como valores próximos da média geral. Apesar disso, o modelo apresentou ótimo desempenho utilizando a base de dados de teste. Em um estudo similar realizado por Morelli-Ferreira et al. (2021), os autores avaliaram diversos algoritmos e IVs para estimar a produtividade de algodão em caroço na região médio-norte do Mato Grosso. Como resposta da pesquisa, constataram que modelos RF e Redes Neurais Artificiais do tipo Multilayer Perceptron apresentaram os melhores desempenhos utilizando IVs.

As limitações do modelo RF foram expostas nas estimativas utilizando a base de dados de validação (lavouras PR122 e PX113), na qual o modelo tendeu a prever a produtividade com 750 kg ha<sup>-1</sup> abaixo do valor real observado (Figura 2C). Tal problema decorre de alguns fatores, dentre eles a necessidade de um banco de dados maior, com variações de produtividade e IVs em diversos tipos de ambientes (maior amplitude do teor de argila). Esse efeito de subestimação dos valores de produtividade na base de dados de validação é uma característica clara de modelos que apresentam um viés originado do banco de dados de treinamento. Como mencionado na análise descritiva, as lavouras PR122 e PX113 apresentaram regiões com valores produtividade acima de 6.000 kg ha<sup>-1</sup>. Os dados dessas lavouras não participaram do treinamento do modelo e as estimativas realizadas não abrangeram produtividades acima de 5.250 kg ha<sup>-1</sup>. Nesse caso, estimativas acima desse valor de produtividade seguiram uma tendência sugerida pelo modelo RF.

Nesse estudo, consideramos um número limitado de lavouras (seis) em apenas uma safra. Algumas perguntas que surgem e que podem ser respondidas em estudos futuros, é a inclusão de mais informações, ou seja, enriquecimento do banco de dados, podendo ser de novas lavouras e/ou safras distintas. A novidade do estudo está na possibilidade de padronização/sintetização das variáveis de entrada do modelo (nesse caso o RF), utilizando técnicas de classificação e redução de dimensionalidade como alternativas que enxergaram padrões de distribuição da saúde das lavouras, que estavam correlacionadas com a produtividade de algodão em caroço.

**CONCLUSÃO:** O fluxo de processos em *machine learning* proposto forneceu ajuste satisfatório do modelo Random Forest aos dados de treinamento. Além disso, indicou ótima precisão nas estimativas da base de dados de teste. No conjunto de dados de validação, o mesmo apresentou clara tendência em subestimar os valores de produtividade de algodão, sendo necessário maior entendimento das causas.

Além de padronizar o número variáveis de entrada, as técnicas de *machine learning* geraram variáveis que descreveram os padrões contidos nos índices de vegetação, e que se correlacionaram com a distribuição espacial do teor de argila do solo. Com isso, as estimativas de produtividade de algodão foram precisas, de acordo com as métricas de avaliação do modelo.

Esse estudo contribui para a área de Agricultura de Precisão em duas perspectivas, a primeira como sugestão de uma metodologia para filtragem e padronização de dados que serão utilizados para produção de modelos de *machine learning*, e a segunda fornecendo *insights* quanto ao uso de variáveis auxiliares que podem melhorar a predição dos modelos que utilizam dados de sensoriamento remoto por satélites.

## REFERÊNCIAS

BONETTI, J.A.; ANGHINONI, I.; DE MORAES, M.T.; FINK, J.R. Resilience of soils with diferente texture, mineralogy and organic matter under long-term conservation systems. **Soil and Tillage Research**. v.174, n.1, 2017. DOI: <https://doi.org/10.1016/j.still.2017.06.008>

COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB. Acompanhamento da safra brasileira: Grãos: safra 2020/2021: Décimo segundo levantamento. Disponível em: <[www.conab.gov.br](http://www.conab.gov.br)>. Acesso em: 19 de abr. 2022.

GERIK, T.J.; OOSTERHUIS, D.M.; TORBERT, H.A. Managing cotton nitrogen. **Advances in Agronomy**, v.64, 1998, 115-147p.

HAWRYŁO, P.; BEDNARZ, B.; WŁYK, P.; SZOSTAK, M. Estimating defoliation of Scots pine stands using machine learning methods and vegetation indices of Sentinel-2. **European Journal of Remote Sensing**. v.51, n.1, 2018. DOI: <https://doi.org/10.1080/22797254.2017.1417745>

JACKSON, R.D.; EZRA, C.E. Spectral response of cotton to suddenly induced water stress. **International Journal of Remote Sensing**. v.6, n.1, 1985. DOI: <https://doi.org/10.1080/01431168508948433>

MORELLI-FERREIRA, F.; MAIA, N.J.; TEDESCO, D.; KAZAMA, E.H.; CARNEIRO, F.M.; SANTOS, L.B.; JUNIOR, G.F.; ROLIM, G.S.; SHIRATSUCHI, L.S.; SILVA, R.P. Comparison of machine learning

techniques in cotton yield prediction using satellite remote sensing. **Preprints**. n. 2021120138, 2021. DOI: <https://doi.org/10.20944/preprints202112.0138.v2>

PARENTE, L.; MESQUITA, V.; MIZIARA, F.; BAUMANN, L.; FERREIRA, L. Assessing the pasturelands and livestock dynamics in Brazil, from 1985 to 2017: A novel approach based on high spatial resolution imagery and Google Earth Engine cloud computing. **Remote Sensing of Environment**. v.232, n.111301, 2019. DOI: <https://doi.org/10.1016/j.rse.2019.111301>

Plant, R.E.; Mermer, A.; Pettygrove, G.S.; Vayssieres, M.P.; Young, J.A.; Miller, R.O.; Jackson, L.F.; Denison, R.F.; Phelps, K. Factors underlying grain yield spatial variability in three irrigated wheat fields. **Transactions of the ASAE**. v.42, n.5, 1999. DOI: <https://doi.org/10.13031/2013.13284>

R CORE TEAM. R: A language and environment for statistical computing. **R Foundation for Statistical Computing**, Vienna, Austria. 2021. URL: <https://www.R-project.org/>

SPEKKEN, M.A.R.K.; ANSELMINI, A.A.; MOLIN, J.P. A simple method for filtering spatial data. Precision agriculture. **Wageningen Academic Publishers**, Wageningen, 2013, 259-266p.

XUE, J.; SU, B. Significant remote sensing vegetation indices: A review of developments and applications. **Journal of sensors**. v.2017, n.1, 2017. DOI: <https://doi.org/10.1155/2017/1353691>

ZHAO, D.; REDDY, K.R.; KAKANI, V.G.; READ, J.J.; KOTI, S. Canopy reflectance in cotton for growth assessment and lint yield prediction. **European Journal of Agronomy**. v.26, n.3, 2007. DOI: <https://doi.org/10.1016/j.eja.2006.12.001>

HAWRY?O, P.; BEDNARZ, B.; W??YK, P.; SZOSTAK, M. Estimating defoliation of Scots pine stands using machine learning methods and vegetation indices of Sentinel-2. **European Journal of Remote Sensing**. v.51, n.1, 2018. DOI: <https://doi.org/10.1080/22797254.2017.1417745>

# Avaliação da viabilidade do pré-processamento de espectros para predição de atributos do solo em tempo real

Ricardo Canal Filho<sup>1</sup>; Marcelo Chan Fu Wei<sup>2</sup>; José Paulo Molin<sup>3</sup>

<sup>1</sup>Eng<sup>o</sup> Agrônomo, Mestrando - Depto. Engenharia de Biossistemas, ESALQ, USP, Piracicaba - SP. ricardocanal@usp.br / (16) 9 9262-8917; <sup>2</sup>Eng<sup>o</sup> Agrônomo, Doutorando - Depto. Engenharia de Biossistemas, ESALQ, USP, Piracicaba - SP; <sup>3</sup>Eng<sup>o</sup> Agrícola, Professor Doutor - Depto. Engenharia de Biossistemas, ESALQ, USP, Piracicaba - SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Na ciência do solo, a região do infravermelho próximo, em inglês *near infrared* (NIR) é a mais estudada para predição de atributos de interesse agrônomo na área da espectroscopia de reflectância difusa, em inglês *diffuse reflectance spectroscopy* (DRS). Os principais objetivos com o uso da técnica é de aumentar a densidade amostral para melhor caracterizar a variabilidade dos atributos do solo. Para isso a técnica precisa ser levada ao campo e tem que ser capaz de lidar com os desafios que a operação de campo apresenta. Para tratar as interferências na leitura, muitos autores têm utilizado técnicas de pré-processamento dos espectros buscando reduzir os ruídos e auxiliar os modelos multivariados a quantificar os atributos de interesse. Entretanto, é limitada a abordagem sobre a efetiva melhora dessa abordagem na predição, e o quanto a adição dessas etapas significa para o processamento dos dados. Desta forma, este estudo propôs proceder essa avaliação a partir da coleta em tempo real de 383 espectros NIR em uma lavoura experimental. Os dados espectrais foram organizados em três conjuntos de dados: dados brutos (DB), sequência de pré-processamento 1 (PP1) e sequência de pré-processamento 2 (PP2). Cada conjunto foi utilizado para prever, via regressão parcial por mínimos quadrados, em inglês *partial least squares regression* (PLSR), seis atributos-chave de fertilidade do solo: argila, areia, matéria orgânica (MO), capacidade de troca catiônica (CTC), pH e potássio (K). Os modelos calibrados apresentaram bons parâmetros de acurácia para quase todos os atributos avaliados, com  $R^2 < 0,60$  apenas para a predição de pH. Apesar disso, considerando a variação dos atributos em campo, os erros de predição de todos os modelos foram consideravelmente baixos. A predição a partir dos espectros de campo pré-processados não diferiu estatisticamente da predição com DB. Contudo, observou-se aumento médio de 200% no tempo demandado de processamento dos dados para predição. O uso de espectros brutos foi a mais eficiente estratégia para uso da DRS NIR para predição de atributos do solo em tempo real.

**PALAVRAS-CHAVE:** quimiometria; espectroscopia no infravermelho próximo; aprendizado de máquina

## EVALUATION OF THE FEASIBILITY OF SPECTRA PRE-PROCESSING TECHNIQUES FOR ONLINE SOIL ATTRIBUTES PREDICTION

**ABSTRACT:** In soil science, the near-infrared region (NIR) is the most studied for predicting attributes of agronomic interest using diffuse reflectance spectroscopy (DRS). The main objectives with the use of the technique is to increase sampling density in order to successfully represent the spatial variability of soil attributes. For this, the technique needs to be taken to the field, being able to deal with the challenges that a field operation can offer. To deal with spectra measure interference, many authors have used spectra pre-processing techniques, in order to reduce noise and aid multivariate models to quantify the attributes of interest. However, it is limited an approach of evaluating if there is an effective improvement in the prediction, and how much the addition of these steps means for data processing. Thus, this study proposed to proceed this evaluation, using 383 online NIR spectra acquired in an experimental field. Spectral data were organized into three datasets: raw data (DB), pre-processing sequence 1 (PP1) and pre-processing sequence 2 (PP2). Each dataset was used to predict, via partial least squares regression (PLSR), six soil fertility key attributes: clay, sand, organic matter (MO), cation exchange capacity (CTC), pH and potassium (K). The calibrated models showed good parameters of accuracy for almost all attributes evaluated, with  $R^2 < 0.60$  only for pH prediction. Despite this, considering the variation of each attribute in the field, the prediction errors of all models were considerably low. The prediction using the pre-processed field spectra did not differ statistically from the prediction with raw spectra. However, an average increase of 200% was observed in the time demanded of

processing data for prediction. The use of raw spectra was the most efficient strategy for the proposed use of DRS NIR of online prediction of soil attributes.

**KEYWORDS:** chemometrics; near-infrared spectroscopy; machine learning

**INTRODUÇÃO:** A espectroscopia de reflectância difusa, em inglês *diffuse reflectance spectroscopy* (DRS) na região do infravermelho próximo, em inglês *near infrared* (NIR) tem demonstrado potencial de aplicação na agricultura para predição de atributos do solo. Essa faixa do espectro eletromagnético exprime interações primárias e secundárias da energia com os atributos do solo (Stenberg et al., 2010). Tais interações ocorrem na forma de absorção, reflexão ou transmissão da energia, e podem ser relacionadas com os atributos do solo em quantidade e qualidade (Nocita et al., 2015).

Estabelecida no meio acadêmico, a DRS NIR tem seu uso documentado principalmente em laboratório. Contudo, um dos desafios para que a técnica contribua efetivamente é torna-la capaz de atuar coletando espectros em tempo real, no campo, a fim de aumentar a densidade amostral dos dados de solo. As densidades amostrais praticadas na maioria das lavouras são comprovadamente ineficazes para identificar adequadamente a variabilidade dos atributos (Wollenhaupt et al., 1994; Montanari et al., 2012; Cherubin et al., 2014; Cherubin et al., 2015), o que resulta em tomadas de decisão questionáveis e consequente gestão ineficiente dos recursos utilizados na produção agrícola.

Pesquisadores têm se dedicado ao uso dos espectros NIR combinados à aplicação de modelos estatísticos multivariados para predição dos atributos de solo (Pasquini et al., 2018). O avanço no uso de métodos de aprendizado de máquina, em inglês *machine learning* (ML) e o uso intensivo da inteligência artificial, vem impulsionando a aplicação de métodos estatísticos multivariados para modelos de predição. É comum a aplicação de técnicas de pré-processamento do espectro antes de inseri-los nas calibrações de ML (Franceschini et al., 2018; Munaf et al., 2021a; Zhang et al., 2021). Essas técnicas possuem o objetivo de remover ruídos, enfatizar feições e extrair informações úteis para os modelos de predição (Dotto et al., 2018). Entretanto, seu uso representa maior demanda de processamento dos dados, fato relevante para aplicações em tempo real. Ainda, alguns dos principais modelos estatísticos utilizados nesta área, como é a regressão parcial por mínimos quadrados (PLSR), são técnicas de redução de dimensionalidade dos dados, auxiliando na remoção de dados ruidosos, redundantes e irrelevantes, semelhante ao objetivo das técnicas de pré-processamento (Velliangiri & Alagumuthukrishnan, 2019). Dessa forma, compreende-se que a viabilidade da aplicação de técnicas de pré-processamento é muitas vezes negligenciada. Com o objetivo de aumentar a densidade de informações acerca do solo, o banco de dados coletado em lavouras comerciais aumenta também e um processamento eficiente é necessário para permitir o uso da técnica em larga escala. Neste sentido, este trabalho se propõe a avaliar a viabilidade de diferentes formas de processamento na construção de modelos de ML para predição de atributos do solo com espectros NIR coletados diretamente em campo, aferindo o custo de processamento e os resultados obtidos pelas diferentes calibrações testadas.

## **MATERIAIS E MÉTODOS:**

Foi utilizada uma área experimental do departamento de Engenharia de Biosistemas da ESALQ/USP, em Piracicaba, SP, com coordenadas centrais 22°43'03.51"S e 47°36'50.03"O, com aproximadamente 6,0 hectares. Nos últimos três anos houve o cultivo de soja na safra de verão e período de pousio durante o inverno. A textura do solo é classificada como franco-arenosa.

Em 2021 foi realizada a coleta de dados espectrais em tempo real utilizando uma estrutura montada no engate hidráulico de três pontos do trator. Nessa estrutura foi acoplado uma haste escarificadora atuando a 0,15 m de profundidade no solo e o fundo do sulco é suavizado pela ponteira da haste. Um compartimento metálico é acoplado na parte traseira da haste por um conjunto pantográfico, e dentro dele é alojado o espectrômetro MicroNIR OnSite-W (Viavi Solutions Inc., California, EUA) que coletou espectros de solo em tempo real na resolução espectral de 908,1-1676,2 nm, com leituras a cada 6,2 nm, resultando em 125 diferentes comprimentos de onda (Figura 1). Os espectros são 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, gravados em um computador portátil conectado ao conjunto. 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). Cada espectro coletado em campo foi associado às suas coordenadas geográficas com uso de um receptor de sistema de navegação global por satélite (GNSS) modelo Ag-Star (Novatel, Calgary, Canadá) com correção diferencial TerraStarC (Hexagon, São Paulo, Brasil).

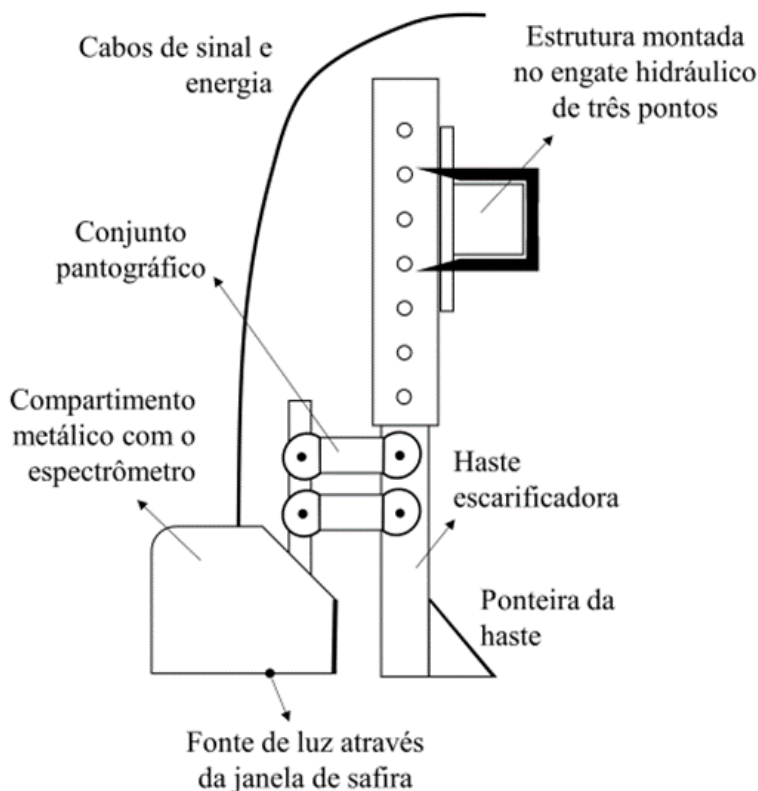


FIGURA 1. Estrutura montada no engate hidráulico de três pontos e haste subsoladora instrumentada com o espectrômetro MicroNIR. **Structure mounted on hydraulic three-point hitch and subsoiler shank with MicroNIR.**

O trator percorreu a área no sentido do tráfego de máquinas, limitado pela presença de terraços e com espaçamento de 12 m, o que resultou em 12 linhas de coleta de dados. Na coleta de espectros em tempo real, o equipamento agrupa amostras e faz uma análise de componentes principais, excluindo amostras que estão fora do limite de confiança estabelecido no software, e assim gera um espectro pela média. A densidade de coleta de espectros foi definida pelo tempo de coleta de 10 segundos à velocidade de  $0,583 \text{ m s}^{-1}$  ( $2,1 \text{ km h}^{-1}$ ), resultando em 383 espectros ao longo da área do experimento (Figura 2).

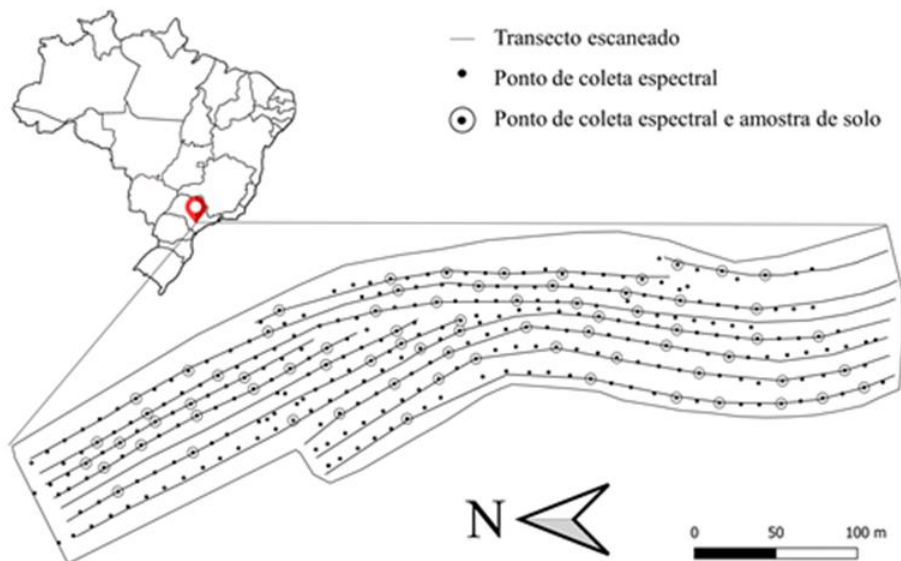


FIGURA 2. Localização da área experimental, em Piracicaba, SP, Brasil. O mapa mostra o contorno da área, os pontos pretos, associados a cada espectro, e os pontos circulados, demarcados para amostragem manual de solo. **Location of experimental area, Piracicaba, SP, Brazil. Plot show the area shape. Black dots alone represent each spectra acquired and black dots contoured represents a spectra associated with a soil sample.**

Um dia após a coleta dos espectros, 72 amostras de solo foram coletadas no fundo do sulco deixado pela haste sulcadora. Com o objetivo de criar calibrações com os espectros de campo, era necessário que cada amostra de solo coincidissem com o respectivo transecto escaneado pelo sensor. Para isso, demarcou-se o início de pontos amostrais apontado pelo software de aquisição de dados espectrais do solo. Após a coleta dos espectros, o produto entre a velocidade de deslocamento e tempo de coleta do software resultou no comprimento do transecto a ser coletado para cada amostra.

As análises físico-químicas do solo foram realizadas por um laboratório comercial. Os atributos utilizados neste estudo e os respectivos métodos de análise foram argila e areia – HMFS+NaOH, matéria orgânica (OM) - oxidação, capacidade de troca catiônica (CTC) – cálculo das bases mais acidez total, pH – CaCl<sub>2</sub> e potássio trocável (K) - resina.

O processamento dos dados de espectros ocorreu no ambiente de programação do software Jupyter Notebook (Kluyver et al., 2016; Python Software Foundation, 2022). Foi conduzida uma análise descritiva e observação espacial dos pontos, para filtrar apenas espectros onde houve um erro claro de medição por alguma condição durante a coleta, como manobras de cabeceira onde o sensor permaneceu ligado, ou perda de calibração do espectrômetro. Essa análise resultou na retirada de 77 espectros, permanecendo 306 no banco de dados.

A estes dados foram adicionados espectros coletados em bancada, de amostras provenientes de A junção de espectros de campo com espectros de bancada no mesmo banco de dados para calibrar modelos de ML é uma estratégia que pode auxiliar no desempenho preditivo do modelo (Munnaf et al., 2019). Ainda, é comprovado que aumentar o número de observações no banco de dados de amostras de solo na calibração de modelos de ML pode auxiliar a predição, sejam essas amostras provenientes da mesma região geográfica ou não (Guerrero et al., 2021).

A fim de comparar o desempenho preditivo com a aplicação de técnicas de pré-processamento, foram criados três bancos de dados: dados brutos (DB), pré-processamento 1 (PP1) e pré-processamento 2 (PP2). Diferentes pré-processamentos foram utilizados para testar o desempenho dessas técnicas, sendo avaliadas por meio do desempenho dos modelos de predição, como proposto por Munnaf et al. (2019).

Os métodos de pré-processamento compreenderam a média móvel (MM), para redução do efeito de bandas ruidosas no espectro; a normalização pelo máximo (NM), que é um método para conformar os espectros na mesma escala e criar uma distribuição uniforme das variações (Rinnan et al., 2009); dois métodos de derivação, a primeira e segunda derivada de Savitzky-Golay (SG), utilizadas para redução de ruído e realçar feições espectrais fracas e possíveis informações ocultas (Ben Dor et al., 1995); e o algoritmo SG de suavização. Esses métodos foram testados em duas sequências (Tabela 1).

TABELA 1. Bancos de dados criados para calibração dos modelos. **Datasets created for models calibration.**

Acrônimo	Ordem de aplicação das técnicas de pré-processamento						
DB	-----						
PP1	MM	+	1ª derivada SG	+	2ª derivada SG	+	algoritmo SG
PP2	MM	+	NM (0,1)	+	1ª derivada SG	+	algoritmo SG

DB: dados brutos; PP1: sequência de pré-processamento 1; PP2: sequência de pré-processamento 2; MM: média móvel, NM: normalização pelo máximo; SG: Savitzky-Golay

Por conseguinte, cada conjunto de dados empregado para o ML foi separado na proporção 70% para calibração e 30% para validação, utilizando a validação cruzada k-fold, definindo-se  $k = 10$ . Esta técnica é recomendada para avaliar modelos de ML, pois geralmente resulta em uma estimativa menos tendenciosa ou menos otimista da habilidade do modelo do que outros métodos (Jung et al., 2018), e consiste basicamente nas etapas: 1) embaralhar o banco de dados (linhas) aleatoriamente; 2) dividir o banco de dados em um número K de grupos; 3) para cada grupo: separar um grupo para validação, utilizar os grupos restantes como um banco de treinamento, ajustar um modelo no conjunto de treinamento e avaliá-lo no conjunto de validação, manter a avaliação e descartar o modelo; 4) resumir a habilidade do modelo pela média das avaliações realizadas. Dessa forma, cada amostra é utilizada uma vez no conjunto de validação e K-1 vezes no conjunto de treinamento, garantindo uma estimativa menos tendenciosa da habilidade de predição do modelo.

Utilizou-se o modelo matemático da regressão parcial por mínimos quadrados, em inglês *partial least squares regression* (PLSR). O PLSR é um método comumente aplicado às análises quantitativas via espectros, pois permite lidar com grande número de variáveis preditoras. Baseia-se em reduzir a dimensão dos dados espectrais gerando novas variáveis, as variáveis latentes (VL). As combinações entre as VL geram o modelo de regressão linear (Kuang et al., 2015).

As métricas utilizadas para avaliação dos modelos preditivos foram o coeficiente de determinação ( $R^2$ ), a raiz do erro quadrático médio (RMSE), o erro médio absoluto (MAE) e a relação de desempenho para distância interquartil (RPIQ). Quanto maiores os valores de  $R^2$  e RPIQ, e menores o RMSE e MAE, subentende-se que melhor foi o desempenho dos modelos. O custo de processamento considerado neste trabalho foi aferido pelo tempo necessário para a máquina realizar uma operação, pela função *datetime* da biblioteca *datetime* do software utilizado (Python Software Foundation, 2022). Os dados foram processados em um notebook com as especificações: SSD NVMe M.2 256 Gb, processador IntelCore i5, memória RAM 8 Gb.

A fim de identificar quais estratégias diferiam estatisticamente e qual seria apontada como melhor desempenho, os valores preditos para cada atributo foram submetidos ao teste de Kruskal-Wallis a 95% de confiança. O teste de Kruskal-Wallis é um teste não-paramétrico, escolhido pelas populações de cada atributo não apresentarem normalidade de distribuição pelo teste de Shapiro-Wilk. A estatística Kruskal-Wallis é utilizada para testar se k grupos são semelhantes. A hipótese nula é de que os grupos são semelhantes, e a hipótese alternativa é que pelo menos um grupo difere dos demais. O teste apresenta os graus de liberdade, a estatística calculada, neste caso o chi-quadrado ( $X^2$ ) e o p-valor calculado.

**RESULTADOS E DISCUSSÃO:** As métricas de avaliação dos modelos de PLSR criados com os três conjuntos de dados para predição dos atributos de solo foram semelhantes (Tabela 2). Para os atributos de

física do solo, argila e areia, em valores absolutos, o modelo de DB apresentou os melhores parâmetros de predição.

TABELA 2. Resultados da validação dos modelos preditivos calibrados com os três conjuntos de dados utilizados neste estudo, testando o uso de espectros de solo brutos e as duas sequências de pré-processamento dos espectros. **Results presented in validation of prediction models calibrated using the three datasets of this study, testing the use of raw soil spectral data and two different spectra pre-processing sequences.**

	DB					PP1					PP2				
	VL	R <sup>2</sup>	RMSE	MAE	RPIQ	VL	R <sup>2</sup>	RMSE	MAE	RPIQ	VL	R <sup>2</sup>	RMSE	MAE	RPIQ
argila	<b>7</b>	<b>0,94</b>	<b>29,22</b>	<b>23,82</b>	<b>8,61</b>	4	0,93	31,68	23,78	8,41	3	0,80	57,04	40,54	4,94
areia	<b>10</b>	<b>0,97</b>	<b>39,12</b>	<b>30,19</b>	<b>12,22</b>	16	0,96	44,76	36,98	10,97	7	0,96	48,38	36,42	9,97
MO	10	0,77	3,15	2,45	3,97	8	0,78	2,94	2,37	4,08	<b>9</b>	<b>0,80</b>	<b>2,87</b>	<b>2,17</b>	<b>4,53</b>
CTC	5	0,65	15,58	10,75	1,68	<b>2</b>	<b>0,69</b>	<b>10,88</b>	<b>7,80</b>	<b>2,02</b>	3	0,56	16,58	11,09	1,57
pH	1	0,29	0,45	0,33	1,33	1	0,29	0,47	0,35	1,17	<b>3</b>	<b>0,48</b>	<b>0,37</b>	<b>0,28</b>	<b>1,20</b>
K	3	0,63	1,72	1,16	1,51	<b>3</b>	<b>0,81</b>	<b>1,44</b>	<b>1,04</b>	<b>4,07</b>	3	0,68	1,72	1,28	2,42

DB: dados brutos; PP1: sequência de pré-processamento 1; PP2: sequência de pré-processamento 2; VL: variáveis latentes/número de componentes utilizados na calibração do modelo; R<sup>2</sup>: coeficiente de determinação; RMSE: raiz do erro quadrático médio; MAE: erro médio absoluto; RPIQ: relação de desempenho para distância interquartil; MO: matéria orgânica; CTC: capacidade de troca catiônica; K: potássio. Destacados em negrito estão os modelos com melhores indicadores por avaliação de valores absolutos.

Destaca-se o modelo de argila de PP2, que apresentou erros de predição – RMSE e MAE - quase duas vezes maiores do que ambos os modelos de DB e PP1. Para a química do solo, a MO, atributo de resposta direta no NIR, através das vibrações fundamentais (Nocita et al., 2015), o melhor modelo foi o de PP2. Entretanto, os parâmetros de avaliação apresentaram valores semelhantes. A CTC, o pH e o K, são atributos de resposta secundária no NIR. Portanto não se espera que eles apresentem feições de absorção diretas nessa região espectral, e o sucesso de suas predições depende da covariância com atributos de resposta primária (Stenberg et al., 2010). Esse fato se concretiza pela análise de correlação de Pearson dos atributos do conjunto de dados deste trabalho (Tabela 3), e observam-se modelos de CTC e K, com R<sup>2</sup> > 0,60 para praticamente todos os modelos, com exceção da predição de CTC por PP2. Destacam-se os modelos de PP1 para a predição destes atributos. O pH foi o atributo que apresentou pior desempenho de predição. Apesar dos baixos erros numéricos quando comparados à variação possível deste atributo no campo (3,0 a 9,0 - Lopes, 1989; Lopes et al., 1990), os valores de R<sup>2</sup> e RPIQ ficaram distantes dos observados para os demais atributos.

TABELA 3. Correlação de Pearson entre os atributos do conjunto de dados deste trabalho. **Pearson's correlation observed on attributes of dataset used in this study.**

	Argila	Areia	MO	CTC	pH	K
Argila	1					
Areia	-0,67	1				
MO	0,25	-0,50	1			
CTC	0,16	-0,44	0,56	1		

pH	0,12	0,28	-0,46	-0,05	1	
K	0,12	-0,17	0,42	0,23	-0,19	1

MO: matéria orgânica; CTC: capacidade de troca catiônica; K: potássio

A avaliação dos valores absolutos permitiria apontar o melhor modelo avaliado. Pode-se, a partir disso, recomendar o uso de uma estratégia – DB, PP1 e PP2 – para cada atributo, como é visto na literatura (Guerrero et al., 2021; Munnaf et al., 2021a). Apontar somente um caminho como o ideal não se torna possível, visto que cada estratégia apresentou, igualmente, dois modelos com melhores parâmetros. Entretanto, é comumente desconsiderado se os melhores parâmetros são fruto de uma variação ao acaso, ou se diferem estatisticamente.

Para aferir se algum modelo apresentou estatisticamente melhor desempenho, os modelos calibrados a partir dos conjuntos de dados DB, PP1 e PP2 foram extrapolados para predição dos atributos em área total, com os espectros de campo coletados na área experimental. Os valores preditos de cada atributo foram submetidos ao teste de Kruskall-Wallis (Tabela 4). Nenhum dos grupos diferiu significativamente de outros a 95% de confiança. Esses resultados denotam que as melhores métricas que apresentaram os modelos preditivos – argila e areia de DB, CTC e K de PP1 e OM e pH de PP2 – não podem ser atribuídas ao tratamento dos dados, mas ao acaso. Dessa forma, a indicação de um modelo de tratamento dos dados para predição dos atributos utilizados neste estudo não é fundamentada.

TABELA 4. Resultados do teste de Kruskall-Wallis para a comparação dos atributos físico-químicos do solo preditos a partir do uso de espectros coletados em campo. **Kruskall-Wallis test results for comparison of physicochemical soil attributes predicted attributes using online NIR spectra.**

	G.L.	X <sup>2</sup>	p-valor
Argila		0,086	0,9577
Areia		1,502	0,4719
MO		3,708	0,1566
CTC	2	1,301	0,5217
pH		5,075	0,0791
K		0,041	0,9795

G.L.: graus de liberdade; X<sup>2</sup>: qui-quadrado; MO: matéria orgânica; CTC: capacidade de troca catiônica; K: potássio

As técnicas de pré-processamento dos espectros são comumente utilizadas para predição de atributos do solo com DRS. Entretanto, os autores tendem a definir um melhor tratamento dos dados com base somente na observação das métricas apresentadas (Benedet et al., 2020; Wang et al., 2020), e outras vezes, ainda, as métricas de avaliação dos modelos não são apresentadas, apenas o tratamento escolhido (Munnaf et al., 2021a; Munnaf et al., 2021b). Por óbvio, o objetivo de remover ruídos, enfatizar feições e extrair as melhores informações para os modelos de ML é factível. Entretanto, a adição de etapas no processamento dos dados deve ser fundamentada, pois representa inevitavelmente maior custo de processamento, exigindo ou maior tempo para predição ou o uso de máquinas mais sofisticadas, encarecendo a aplicação da técnica e dificultando a sua difusão. Assim, aferiu-se o tempo de processamento da máquina para realizar dez vezes a predição de cada atributo a partir dos modelos calibrados com os três bancos de dados. O tempo de cada repetição foi calculado pela média da predição dos seis atributos avaliados (Tabela 5). O tempo demandado para predição a partir dos espectros com pré-processamento foi, em média, 200% maior do que a partir do banco de dados calibrado com os dados espectrais brutos.

TABELA 5. Custo de processamento médio aferido pelo tempo demandado pela máquina para realizar dez predições dos seis atributos avaliados neste estudo. **Average processing cost measured by the time demanded by the machine to predict ten times the six attributes evaluated in this study.**

	DB	PP1	PP2
	segundos		
1	0,1346	0,2692	0,2692
2	0,0470	0,0997	0,1012
3	0,1037	0,2074	0,2074
4	0,1166	0,2356	0,2333
5	0,1306	0,2586	0,2639
6	0,1126	0,2422	0,2422
7	0,1346	0,2558	0,2558
8	0,1152	0,2315	0,2315
9	0,0985	0,1757	0,2010
10	0,1198	0,2397	0,2397
Média	0,1113	0,2216	0,2245
%	-	199%	202%

DB: dados brutos; PP1: sequência de pré-processamento 1; PP2: sequência de pré-processamento 2; %: porcentagem comparado ao modelo de menor tempo de processamento – DB.

Dessa forma, sugere-se que a adição das etapas demandadas pelo pré-processamento acarretou no dobro do custo de processamento, aqui aferido pelo tempo demandado para predição, sem ganho de acurácia preditiva nos modelos de ML. Portanto, não há sentido prático em indicar o uso de técnicas de pré-processamento do espectro para a predição dos atributos de solo a partir da DRS NIR em tempo real no cenário proposto neste estudo.

**CONCLUSÃO:** Os modelos calibrados apresentaram bons parâmetros de acurácia tanto para os atributos físicos – argila e areia - como para os atributos químicos do solo – MO, CTC, pH, K - na área de estudo. Os atributos secundários puderam ser preditos provavelmente pela correlação que apresentaram com atributos de resposta primária no NIR. Nenhum grupo de valores preditos, para nenhum dos seis atributos avaliados, diferiu estatisticamente dos demais, denotando que as pequenas variações observadas em cada predição podem ser atribuídas ao acaso. O uso de técnicas de pré-processamento não atingiu o objetivo esperado de auxiliar significativamente a predição de atributos do solo pelo tratamento dos espectros coletados em campo. Contudo, a aplicação dessas técnicas aumentou o tempo demandado pela máquina para predição dos espectros de campo da área de estudo. Sugere-se que o uso dos dados brutos foi o mais eficiente para o cenário avaliado neste trabalho.

#### REFERÊNCIAS

Ben-Dor, E., & Banin, A. Near-infrared analysis as a rapid method to simultaneously evaluate several soil properties. **Soil Science Society of America Journal**, 59(2), 364-372. 1995.

- Benedet, L., Faria, W. M., Silva, S. H. G., Mancini, M., Demattê, J. A. M., Guilherme, L. R. G., & Curi, N. Soil texture prediction using portable X-ray fluorescence spectrometry and visible near-infrared diffuse reflectance spectroscopy. **Geoderma**, 376, 114553. 2020.
- Cherubin, M. R., Santi, A. L., Eitelwein, M. T., Menegol, D. R., Ros, C. O. D., Pias, O. H. D. C., & Berghetti, J. Eficiência de malhas amostrais utilizadas na caracterização da variabilidade espacial de fósforo e potássio. **Ciência Rural**, 44, 425-432. 2014.
- 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**, 50(2), 168-177. 2015.
- Dotto, A. C., Dalmolin, R. S. D., ten Caten, A., & Grunwald, S. A systematic study on the application of scatter-corrective and spectral-derivative preprocessing for multivariate prediction of soil organic carbon by Vis-NIR spectra. **Geoderma**, 314, 262-274. 2018.
- Franceschini, M. H. D., Demattê, J. A. M., Kooistra, L., Bartholomeus, H., Rizzo, R., Fongaro, C. T., & Molin, J. P. Effects of external factors on soil reflectance measured on-the-go and assessment of potential spectral correction through orthogonalisation and standardisation procedures. **Soil and Tillage Research**, 177, 19-36. 2018.
- Guerrero, A., De Neve, S., & Mouazen, A. M. Data fusion approach for map-based variable-rate nitrogen fertilization in barley and wheat. **Soil and Tillage Research**, 205, 104789. 2021.
- Kuang, B., Tekin, Y., Mouazen, A.M., 2015. Comparison between artificial neural network and partial least squares for on-line visible and near infrared spectroscopy measurement of soil organic carbon, pH and clay content. **Soil Tillage Research**. 146, 243–252. 2015.
- LOPES, A.S. Manual de fertilidade do solo. São Paulo: ANDA/POTAFOS. 153 p. 1989.
- LOPES, A. S.; SILVA, M. C.; GUILHERME, L. R. Acidez do solo e calagem. 3a ed. Ver. ANDA. 22 p. **Boletim Técnico**. 1990.
- Montanari, R., Souza, G. S. A., Pereira, G. T., Marques, J. U. N. I. O. R., Siqueira, D. S., & Siqueira, G. M. The use of scaled semivariograms to plan soil sampling in sugarcane fields. **Precision Agriculture**, 13(5), 542-552. 2012.
- Munnaf, A. M., Nawar, S., & Mouazen, A. M. Estimation of Secondary Soil Properties by Fusion of Laboratory and On-Line Measured Vis–NIR Spectra. **Remote Sensing**, 11(23), 2819. 2019.
- Munnaf, M. A., Guerrero, A., Nawar, S., Haesaert, G., Van Meirvenne, M., & Mouazen, A. M. A combined data mining approach for on-line prediction of key soil quality indicators by Vis-NIR spectroscopy. **Soil and Tillage Research**, 205, 104808. 2021a.
- Munnaf, M. A., Haesaert, G., Van Meirvenne, M., & Mouazen, A. M. Multi-sensors data fusion approach for site-specific seeding of consumption and seed potato production. **Precision Agriculture**, 22(6), 1890-1917. 2021.
- Nocita, M., Stevens, A., van Wesemael, B., Aitkenhead, M., Bachmann, M., Barthès, B., ... & Wetterlind, J. Soil spectroscopy: An alternative to wet chemistry for soil monitoring. In **Advances in agronomy** (Vol. 132, pp. 139-159). Academic Press. 2015.
- Pasquini, C. (2018). Near infrared spectroscopy: A mature analytical technique with new perspectives—A review. **Analytica chimica acta**, 1026, 8-36.
- Rinnan, Å., Van Den Berg, F., & Engelsen, S. B. Review of the most common pre-processing techniques for near-infrared spectra. **TrAC Trends in Analytical Chemistry**, 28(10), 1201-1222. 2009.



- Stenberg B., Viscarra Rossel R.A., Mouazen A.M., & Wetterlind J. Visible and near-infrared spectroscopy in soil science. **Advances in Agronomy**, 107: 163-215. 2010.
- Velliangiri, S., & Alagumuthukrishnan, S. (2019). A review of dimensionality reduction techniques for efficient computation. **Procedia Computer Science**, 165, 104-111.
- Wang, Y. P., Lee, C. K., Dai, Y. H., & Shen, Y. Effect of wetting on the determination of soil organic matter content using visible and near-infrared spectrometer. **Geoderma**, 376, 114528. 2020.
- Wollenhaupt, N. C., Wolkowski, R. P., & Clayton, M. K. Mapping soil test phosphorus and potassium for variable-rate fertilizer application. **Journal of production agriculture**, 7(4), 441-448. 1994.
- Zhang, J., Guerrero, A., & Mouazen, A. M. Map-based variable-rate manure application in wheat using a data fusion approach. **Soil and Tillage Research**, 207, 104846. 2021.

# ABORDAGENS COM COMPLEXIDADES DISTINTAS PARA O DELINEAMENTO DE UNIDADES DE GESTÃO DIFERENCIADA

Henrique Oldoni<sup>1</sup>; Joaquim Pedro de Lima<sup>2</sup>; Agda Loureiro Gonçalves Oliveira<sup>2</sup>; Lucas Rios do Amaral<sup>3</sup>; Paulo Sérgio Graziano Magalhães<sup>4</sup>

<sup>1</sup>Eng° Agrícola, Dr., Pós-doutorando - Núcleo Interdisciplinar de Planejamento Energético - NIPE, UNICAMP, Campinas - SP. holdoni@unicamp.br / (14) 9 9794-2247; <sup>2</sup>Eng° Agrícola, Doutorando - Programa de Pós-Graduação em Engenharia Agrícola - FEAGRI, UNICAMP, Campinas - SP; <sup>3</sup>Eng° Agrônomo, Dr., Professor - Faculdade de Engenharia Agrícola - FEAGRI, UNICAMP, Campinas - SP; <sup>4</sup>Eng° Agrícola, Dr., Pesquisador - Núcleo Interdisciplinar de Planejamento Energético - NIPE, UNICAMP, Campinas - SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Diversos são os fatores que influenciam na qualidade das unidades de gestão diferenciadas (UGDs), como as diferentes abordagens de delineamento. Embora diversas abordagens mostrem-se satisfatórias, as mais complexas muitas vezes são preferidas pelos usuários quando a intenção é obter UGDs de melhor qualidade, no entanto, demandam maior tempo para implementação e entendimento do processo. O objetivo deste estudo foi avaliar se uma abordagem de delineamento de UGDs de maior complexidade (abordagem A), resulta em UGDs de melhor qualidade quando comparada à uma abordagem menos complexa (abordagem B). O estudo foi desenvolvido em uma área de integração lavoura-pecuária, localizada no município de Caiuá-SP. Amostras de solo foram coletadas para determinação dos teores de argila, silte, matéria orgânica e capacidade de troca catiônica. Dados de condutividade elétrica aparente do solo, elevação e declividade do terreno, produtividade da soja e pastagem foram adquiridos. A abordagem A, mais complexa, diferencia-se da B principalmente por adotar a seleção de atributos pela análise MULTISPATI-PCA. Ambas as abordagens de delineamento de UGDs foram implementadas utilizando os dados de solo e terreno. A avaliação da qualidade dos agrupamentos foi realizada a partir de índices de agrupamento, e a avaliação da qualidade das UGDs pela redução da variância e teste de comparação múltipla aplicados aos dados de solo e produtividade da soja e pastagem. De modo geral, as abordagens A e B apresentaram resultados semelhantes quanto à qualidade da delimitação de UGDs, com superioridade da abordagem A em algumas ocasiões. Portanto, tal abordagem, de maior complexidade, garante maior qualidade do delineamento de UGDs quando comparada à abordagem menos complexa (abordagem B), porém, não de maneira consistente.

**PALAVRAS-CHAVE:** métodos de agrupamento; zonas de manejo; sistema de integração lavoura-pecuária

## APPROACHES WITH DIFFERENT COMPLEXITIES FOR MANAGEMENT ZONES DELINEATION

**ABSTRACT:** Several factors influence the quality of management zones (MZs), such as the different delineation approaches. Although several approaches proved to be satisfactory, users often prefer the more complex ones when the intention is to obtain better quality MZs. However, it takes longer to implement and understand the process. This study aimed to assess whether a more complex MZ delineation approach, (approach A) improves MZs quality than a less complex approach (approach B). The study was developed in an integrated crop-livestock system area located in the municipality of Caiuá-SP, Brazil. Soil samples were collected to determine the attributes: clay, silt, organic matter and cation exchange capacity. Data on soil apparent electrical conductivity, terrain elevation and slope, and soybean and pasture yield were acquired. Approach A, more complex, differs from B mainly by adopting the feature selection by the MULTISPATI-PCA analysis. Both MZ delineation approaches were implemented on soil and terrain data. The cluster quality evaluation was carried out from cluster indices, and the MZs quality was evaluated using variance reduction and a multiple comparison test applied to soil and yield data. In general, approaches A and B showed similar results regarding the MZs delineation quality, with the approach A being superior on some occasions. Therefore, this approach guarantees higher MZs delineation quality when compared to the less complex approach (approach B), however, not consistently.

**KEYWORDS:** clustering methods; management zones; integrated crop-livestock system

**INTRODUÇÃO:** A divisão das áreas agrícolas em Unidades de gestão diferenciada (UGDs) é uma abordagem interessante da agricultura de precisão que pode auxiliar em diversas frentes de manejo da culturas, como na aplicação de insumos (PERALTA et al., 2015) e sementes (CAMICIA et al., 2018) em taxa variada e na colheita seletiva (KAZAMA et al., 2021), de modo a maximizar o uso de insumos, produção das culturas e qualidade da produção. As UGDs podem ser consideradas como sub-regiões de uma área agrícola que combinam em seu interior diversos fatores, como características de solo, relevo e vegetação, com comportamento relativamente homogêneo no espaço e no tempo. A delimitação de UGDs em áreas agrícolas ainda é um processo desafiador dentro da agricultura de precisão. Diversos são os fatores que influenciam na qualidade das UGDs, como as variáveis de entrada, ou seja, ao se utilizar apenas mapas de produtividade (DIKER; HEERMANN; BRODAHL, 2004), atributos do solo (HAGHVERDI et al., 2015), dados de sensoriamento remoto (BREUNIG et al., 2020), ou a combinação dessas camadas de informação (DERBY; CASEY; FRANZEN, 2007). Além disso, os métodos empregados na construção das UGDs podem também interferir significativamente em sua qualidade (GUASTAFERRO et al., 2010; HAGHVERDI et al., 2015).

Alguns estudos buscaram estabelecer determinadas rotinas para o delineamento de UGDs, como é o caso de Córdoba et al. (2016) e Javadi, Guerrero e Mouazen (2022). Córdoba et al. (2016) apresentam em seu estudo uma abordagem que integra diferentes ferramentas estatísticas para delinear UGDs, tais como padronização dos dados, análise espacial multivariada baseada no índice de Moran e em componentes principais (MULTISPATI-PCA) (DRAY; SAÏD; DÉBIAS, 2008), seguida por análise de agrupamento *fuzzy k-means* (BEZDEK; EHRLICH; FULL, 1984). Esta abordagem é considerada complexa em termos conceituais e computacionais quando comparada a outras abordagens mais simples, como é o caso da proposta por Javadi, Guerrero e Mouazen (2022). Esses autores avaliaram a performance de diferentes algoritmos de agrupamento e o impacto do formato dos dados de entrada e seleção de atributos na qualidade do delineamento de UGDs, de modo que chegaram a uma abordagem mais simples. Essa abordagem envolve principalmente a normalização de dados, seguida por uma seleção de atributos baseada em correlação de Pearson e análise de agrupamento *k-means* (MACQUEEN, 1967).

Tem-se a percepção que abordagens mais complexas entregam consistentemente melhores resultados. Isso faz com que a adoção da técnica pelos usuários finais seja dificultada. Contudo, tal desempenho superior não é garantia. Portanto, o objetivo foi avaliar se uma abordagem de maior complexidade para o delineamento de UGDs (abordagem A), resulta em UGDs de melhor qualidade quando comparada à uma abordagem menos complexa (abordagem B).

**MATERIAIS E MÉTODOS:** O estudo foi desenvolvido em uma área de integração lavoura-pecuária de 105 ha, localizada no município de Caiuá, Oeste do Estado de São Paulo. Uma malha com 213 pontos georreferenciados foi estabelecida na área para realização da coleta de amostras de solo na camada de 0-0,20 m, em outubro de 2018. Em cada ponto de amostragem, quatro subamostras foram coletadas no interior de um raio de 4 m para compor a amostra composta de cada ponto. As amostras foram submetidas a análises laboratoriais para determinação dos atributos de solo argila, silte, matéria orgânica (MO) e capacidade de troca catiônica (CTC), por serem atributos que, de certa forma, tendem a reger o comportamento dos demais. Além disso, dados de condutividade elétrica aparente do solo (CEa) foram coletados em abril de 2019 por meio do sensor de indutância eletromagnética EM38-MK2® (Geonics, Mississauga, Ontário, Canadá), em passadas de 30 m, na camada de solo de 0-0,38 m. Dados de terreno, i.e., elevação e declividade, foram derivados de um modelo digital de elevação extraído do sensor PALSAR (Phased Array type L-band Synthetic Aperture Radar) acoplado ao satélite ALOS (Advanced Land Observing Satellite). Dados de produtividade da pastagem foram adquiridos em maio de 2019 por meio de amostragem manual da parte aérea da biomassa em 1 m<sup>2</sup> de 50 pontos georreferenciados, estabelecidos aleatoriamente na área. Por fim, dados de produtividade da soja da safra de 2019/20 foram adquiridos e georreferenciados por meio de um monitor de colheita GreenStar™ 3 2630 e receptor GNSS acoplados a uma colheitadeira John Deere S550.

Os dados de solo e produtividade da soja e pastagem foram submetidos a um pré-processamento para identificação e remoção de possíveis *outliers* e *inliers*. Em especial, os dados de CEa e produtividade da soja foram submetidos a um processo de filtragem de dados seguindo o procedimento descrito em Maldaner et al.

(2022). Na sequência, realizou-se a análise geostatística dos dados de solo (argila, silte, MO, CTC e CEa) e interpolação por krigagem para a obtenção de mapas interpolados com uma resolução espacial de 5 m. Os pixels dos mapas de elevação e declividade foram reamostrados para que estivessem na mesma resolução espacial dos dados de solo.

Com posse dos mapas de solo e terreno, foram delineadas as UGDs seguindo as abordagens A e B. A abordagem A foi baseada em etapas do protocolo de Córdoba et al. (2016) e apresenta as seguintes etapas para a delimitação das UGDs: 1) padronização dos dados pelo método z-score; 2) seleção de atributos por MULTISPATI-PCA, sendo a matriz de ponderação espacial construída a partir do método baseado na distância euclidiana para definir a vizinhança de pontos e com melhor distância entre pontos vizinhos adotada para 25 m, e seleção de apenas as componentes principais espaciais (sPC) que juntas somam mais de 70% da variância total; 3) aplicação da análise de agrupamento por meio do algoritmo *fuzzy k-means* às sPCs selecionadas na etapa anterior, considerando expoente de ponderação *fuzzy* de 1,3, máximo de 300 iterações, e testando entre dois e cinco grupos; e 4) suavização das UGDs delimitadas. Já a abordagem B foi baseada na melhor estratégia para delimitação de UGDs identificada em Javadi, Guerrero e Mouazen (2022), e apresenta as seguintes etapas: 1) normalização dos dados no intervalo entre 0 e 1; 2) seleção de atributos baseado na correlação espacial de Pearson, com eliminação de uma de duas variáveis quando o coeficiente de correlação for acima de  $|0,70|$ ; 3) aplicação da análise de agrupamento *k-means* aos atributos normalizados e selecionados nas etapas anteriores, testando entre dois e cinco grupos; e 4) suavização das UGDs delimitadas. Em ambas as abordagens, a suavização das UGDs foi realizada usando um filtro de mediana (GONZALEZ; WOODS, 2008) e uma máscara de 12x12 pixels. Além disso, ambas as abordagens partiram do mesmo conjunto de dados (argila, silte, MO, CTC, CEa, elevação e declividade).

A avaliação da qualidade dos agrupamentos gerados foi realizada a partir de dois índices: o índice de silhueta (SI) (ROUSSEEUW, 1987) e o índice de Davies-Doublin (DBI) (DAVIES; BOULDIN, 1979). Quanto maior for o valor de SI e menor de DBI, maior é a qualidade dos grupos gerados nas análises de agrupamento. Além disso, foi avaliada a qualidade do delineamento das UGDs por meio da determinação da variância reduzida (VR) (PING; DOBERMANN, 2003) e por meio da avaliação das diferenças entre UGDs quanto aos dados de solo e produtividade. Quanto maior a redução da variância intra-UGD, ou seja, quanto maior o valor de VR, melhor é a qualidade do delineamento das UGDs (JAVADI; GUERRERO; MOUAZEN, 2022). Para a determinação de um valor de VR geral, foi determinado a média dos valores de  $VR_{\theta}$  de cada um dos atributos de amostragem de solo (argila, silte, MO e CTC) e para os dados de produtividade da soja e pastagem. Para a avaliação das diferenças entre UGDs, os dados amostrados em 50 pontos de argila, silte, MO, CTC, produtividade da soja e da pastagem foram inicialmente submetidos aos testes de normalidade de Shapiro-Wilk e homogeneidade da variância de Bartlett. Em seguida, no caso de não normalidade ou heterogeneidade de variância dos dados, o teste não paramétrico Kruskal-Wallis foi aplicado, seguido pelo teste *post-hoc* de Dunn para as comparações múltiplas, com ajuste de p-valor pelo método de Bonferroni. Em caso de normalidade e homogeneidade de variância foi aplicada a análise de variância *one-way*, seguida pelo teste *post-hoc* de Tukey HSD. Considerou-se um nível de significância de 5% para todos os testes.

**RESULTADOS E DISCUSSÃO:** Na etapa de seleção de atributos da abordagem B, baseada na correlação cruzada (TABELA 1), todos os atributos disponíveis foram selecionados para a etapa da análise de agrupamento *k-means*, devido a todos os coeficientes de correlação permanecerem abaixo de 0,70. Para a etapa de seleção de atributos da abordagem A, realizada a partir da MULTISPATI-PCA, as três primeiras componentes principais espaciais foram selecionadas para a etapa da análise de agrupamento *fuzzy k-means*, sendo que sPC-1, sPC-2 e sPC-3 explicaram 33%, 30% e 13% da variância total, respectivamente, o que somou mais de 70% da variância total.

TABELA 1. Matriz de correlação de Pearson dos atributos de solo e terreno. **Pearson correlation matrix of the soil and terrain attributes.**

Atributo	Argila	Silte	MO	CTC	CEa05	Elevação	Declividade
Argila	1						

Atributo	Argila	Silte	MO	CTC	CEa05	Elevação	Declividade
Silte	0,177	1					
MO	0,254	0,056	1				
CTC	0,240	0,227	0,518	1			
CEa	0,616	0,216	0,077	0,158	1		
Elevação	0,120	0,104	0,360	0,336	-0,355	1	
Declividade	-0,014	0,036	0,115	0,139	-0,179	0,324	1

Os resultados das análises de agrupamento, realizada para um número de dois a cinco grupos em ambas as abordagens, foram transformados em potenciais mapas de UGDs (FIGURA 1). Ao realizar-se um comparativo entre mapas de diferentes abordagens (A e B) em um mesmo número de UGDs, nota-se que existem diferenças no delineamento, com principal destaque para a configuração de quatro UGDs (FIGURAS 1c e 1g), mostrando as maiores diferenças entre os delineamentos resultantes das duas abordagens testadas. Por outro lado, ao comparar os mapas com três UGDs (FIGURAS 1b e 1f), notadamente apresentaram elevada semelhança.

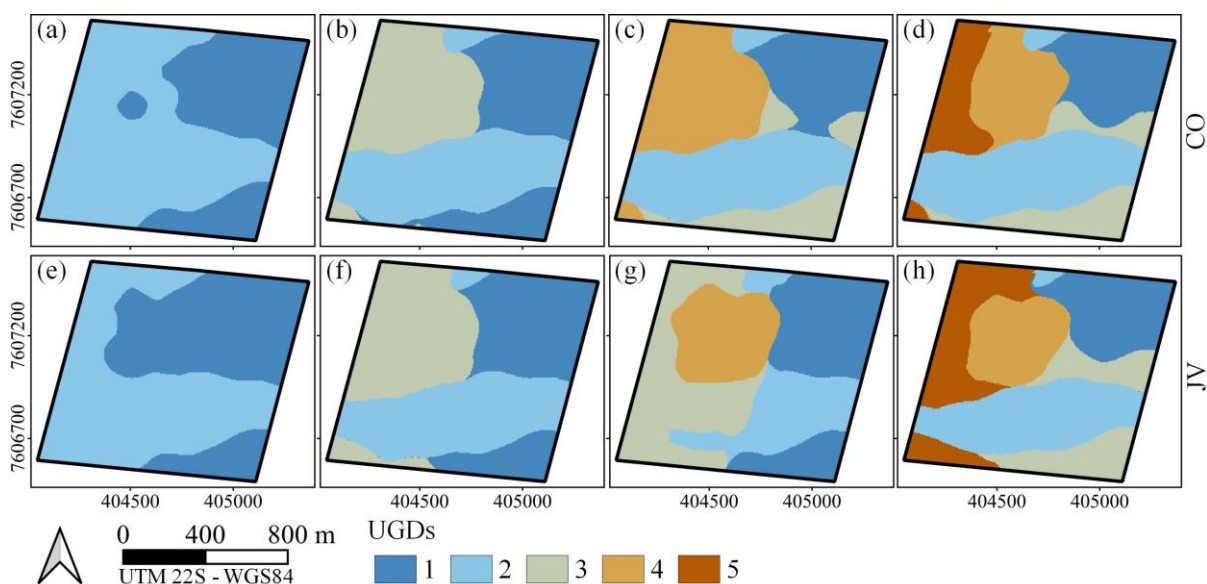


FIGURA 1. Potenciais mapas de unidades de gestão diferenciada (UGDs) delineadas a partir das abordagens A (CO; a-d) e B (JV; e-h), com duas (a, e), três (b, f), quatro (c, g) e cinco (d, h) UGDs. **Potentials management zone (UGDs) maps delineated by approaches A (CO; a to d) and B (JV; e to h), with two (a, e), three (b, f), four (c, g) and five (d, h) UGDs.**

Com base nos valores de SI e DBI (FIGURA 2), é possível identificar que o melhor número de UGDs foi três (maiores valores de SI e menores de DBI). Esses índices também indicaram que a abordagem A resultou em uma maior qualidade da análise de agrupamento independentemente do número de UGDs (maiores valores de SI e menores de DBI). No entanto, o número de atributos utilizados para a análise de agrupamento pode interferir nos valores destes índices, sendo quanto maior o número de atributos, menor tende a ser o valor do SI e maior o DBI. De fato, a abordagem A utilizou menos atributos na análise de agrupamento (três atributos; PC-1, sPC-2 e sPC-3) do que a abordagem B (sete atributos; solo e relevo). Isso pode ter ocasionado uma falsa percepção de que a qualidade dos agrupamentos foi maior na abordagem A. Isso é evidente ao se confrontar os resultados da Figura 1 e 2, principalmente para três UGDs. Neste número de UGDs, os mapas apresentaram elevada semelhança (FIGURAS 1b e 1f) entre abordagens, o mesmo deveria ser observado na Figura 2 para os índices SI e DBI, o que não ocorreu. Portanto, a comparação clara entre as abordagens quanto a qualidade dos agrupamentos não foi possível.

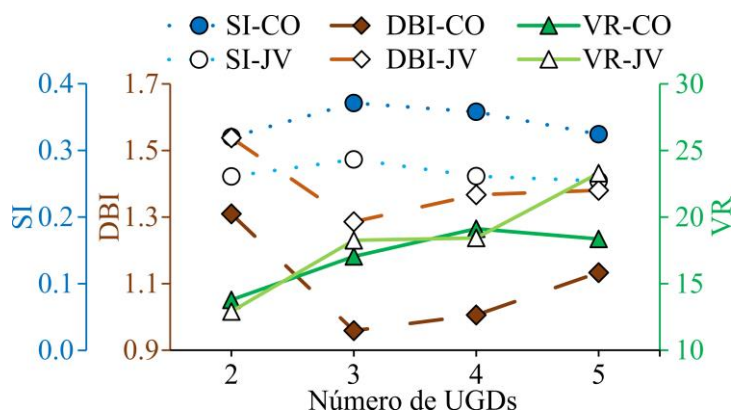


FIGURA 2. Avaliação das abordagens A (CO) e B (JV) para delimitação de unidades de gestão diferenciada (UGDs) a partir do índice de silhueta (SI), índice de Davies-Doublin (DBI), e redução da variância (VR), para duas, três, quatro e cinco UGDs. **Evaluation of A (CO) and B (JV) management zones (UGDs) delineation approaches in terms of Silhouette index (SI), Davies-Doublin index (DBI), and variance reduction (VR) to two, three, four and five UGDs.**

Por outro lado, os valores de VR indicaram claramente semelhança na qualidade do delineamento das UGDs de ambas as abordagens, exceto quando cinco UGDs foram delineadas, indicando um delineamento de maior qualidade com a abordagem B (maior VR). Além disso, embora o número de quatro UGDs tenha resultado nas maiores diferenças entre mapas (FIGURA 1), os valores de VR foram altamente semelhantes nesta configuração (FIGURA 2). Porém, como este índice representa a média dentre os atributos de solo e produtividade, as diferenças entre VR<sub>0</sub> que favoreceram à uma ou outra abordagem foram diluídas.

Embora a qualidade dos agrupamentos gerados pela abordagem A tenha sido maior (SI e DBI; FIGURA 2), a qualidade do delineamento de UGDs não seguiu o mesmo caminho (VR; FIGURA 2), diante de que a qualidade de delineamento ora foi semelhante entre abordagens (duas, três e quatro UGDs) e ora foi maior para JV (cinco UGDs). Portanto, não foi possível destacar uma única melhor abordagem entre as duas. De fato, a qualidade dos agrupamentos é um fator importante no delineamento de UGDs, e muitas vezes indica o melhor número de UGDs a ser adotado (JAVADI; GUERRERO; MOUAZEN, 2022). No entanto, a resposta do delineamento quanto a sua capacidade em distinguir as diferentes características de solo e produção da área também deve ser considerada na avaliação, sendo esta de maior importância. O VR permite avaliar essa resposta a partir da quantificação da redução da variância interna das UGDs em relação a variância total da área de cada atributo do solo e da produtividade das culturas.

Além do VR, avaliar as diferenças dos atributos entre as UGDs também permite avaliar a qualidade do delineamento (TABELA 2). De modo geral, as abordagens A e B apresentaram resultados semelhantes quanto a capacidade de distinção das UGDs em diferentes níveis de atributos do solo e produtividade de soja e pastagem. No entanto, em alguns casos (apenas para duas e quatro UGDs) a abordagem A foi superior quando apenas esta apresentou diferença significativa entre UGDs ( $p$ -valor $<0,05$ ), como para a produtividade da pastagem com quatro UGDs, MO para duas e quatro UGDs e CTC para duas UGDs. Vale ressaltar que duas e principalmente quatro UGDs apresentaram as maiores diferenças entre mapas quando comparadas ambas as abordagens (FIGURA 1), o que corrobora com este resultado. Quando observado apenas os resultados do melhor cenário (três UGDs), como indicado na Figura 2, ambas as abordagens apresentaram resultados semelhantes quanto as diferenças entre as UGDs para todos os atributos (TABELA 2), além de VR (FIGURA 2). Isso demonstra que nesse caso as abordagens foram altamente semelhantes.

TABELA 2. Resultado dos testes de comparação múltipla aplicados às variáveis de produtividade e solo nas abordagens A e B. **Results of multiple comparison tests applied to yield and soil variables in the A and B approaches.**

Variável	Número de UGDs	Abordagem	UGD-1	UGD-2	UGD-3	UGD-4	UGD-5
Produtividade da soja	2	A	b	a			

		B	b	a			
	3	A	b	a	ab		
		B	b	a	b		
	4	A	b	a	ab	ab	
		B	bc	a	ab	b	
	5	A	b	a	ab	ab ab	
		B	b	a	ab	ab ab	
Produtividade da pastagem	2	A	a	a			
		B	a	a			
	3	A	a	a	a		
		B	a	a	a		
	4	A	a	b	b	ab	
		B	a	a	a	a	
	5	A	a	b	b	ab ab	
		B	a	b	b	ab b	
	Argila	2	A	b	a		
			B	b	a		
3		A	b	a	b		
		B	b	a	b		
4		A	b	a	b	b	
		B	b	a	a	b	
5		A	b	a	b	b ab	
		B	b	a	b	bc ab	
Silte		2	A	b	a		
			B	b	a		
	3	A	b	a	ab		
		B	b	a	ab		
	4	A	b	a	ab	ab	
		B	b	a	ab	ab	



Matéria orgânica	5	A	b	a	ab	ab	ab
		B	b	a	ab	ab	ab
	2	A	b	a			
		B	a	a			
	3	A	b	ab	a		
		B	b	ab	a		
	4	A	ab	ab	b	a	
		B	a	a	a	a	
	5	A	ab	ab	b	ab	a
		B	ab	ab	b	ab	a
Capacidade de troca catiônica	2	A	b	a			
		B	a	a			
	3	A	b	a	a		
		B	b	a	a		
	4	A	b	ab	bc	a	
		B	b	a	a	a	
	5	A	b	ab	bc	a	ab
		B	ab	a	b	a	a

Diferentes letras em uma mesma linha representam diferença significativa no teste de comparação múltipla ( $p\text{-valor} \leq 0,05$ ) entre UGDs.

A abordagem A, embora de maior complexidade, na maioria das vezes apresentou qualidade do delineamento de UGDs semelhante à abordagem B, principalmente no melhor cenário (três UGDs), como demonstrado pelos valores de VR (FIGURA 2) e nas diferenças entre UGDs (TABELA 2). No entanto, em alguns casos apenas a abordagem A permitiu diferenciar os atributos entre UGDs. Isso indica que o delineamento de UGDs promovido pela redução de dimensionalidade dos dados a partir da MULTISPATI-PCA e por uma análise de agrupamento *fuzzy* trouxe benefícios na qualidade do delineamento. Porém, esta maior qualidade pode não ser proporcional positivamente à maior complexidade da abordagem A. A MULTISPATI-PCA na etapa de seleção de atributos demanda maior poder computacional quando comparado a uma simples análise de correlação de Pearson entre os atributos. Além da aplicação da análise de componentes principais, a MULTISPATI-PCA necessita também da construção de uma matriz de ponderação definida por uma análise de autocorrelação espacial local (CÓRDOBA et al., 2016). Somado a isso, demanda e a necessidade de escolha do método para definir a vizinhança dos pontos para a determinação da matriz de ponderação espacial (DRAY et al., 2006) e, a depender disso, testes para identificar o melhor número de vizinhos a ser adotado ou testes para identificar qual melhor raio de vizinhança, o qual pode variar de área em área (GAVIOLI, 2017). Quanto aos métodos de agrupamento, Javadi, Guerrero e Mouazen (2022) destaca que *k-means* (rígido) e *fuzzy k-means* (*fuzzy*) funcionam de maneira semelhante, no entanto, o método *fuzzy* necessita de um hiperparâmetro adicional, o expoente de ponderação *fuzzy*, do qual seu valor ainda não foi especificado de maneira clara pela comunidade científica, portanto, outro complicador da abordagem A.

**CONCLUSÃO:** A abordagem de maior complexidade computacional e conceitual, abordagem A, garante maior qualidade do delineamento de UGDs quando comparada à abordagem B, porém, não maneira consistente. A abordagem B, como menos complexa, pode ser utilizada para delinear UGDs quando a simplificação do processo de delineamento de UGDs é necessária, com baixo prejuízo à qualidade do delineamento.

#### **AGRADECIMENTOS:**

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), processos nº 2017/50205-9 e 2020/02223-0; e à Fazenda Campina (CV Nelore Mocho) pelo suporte e assistência.

#### **REFERÊNCIAS**

BEZDEK, J. C.; EHRLICH, R.; FULL, W. FCM: The fuzzy c-means clustering algorithm. **Computers and Geosciences**, v. 10, n. 2–3, p. 191–203, 1984.

BREUNIG, F. M. et al. Delineation of management zones in agricultural fields using cover–crop biomass estimates from PlanetScope data. **International Journal of Applied Earth Observation and Geoinformation**, v. 85, p. 102004, 2020.

CAMICIA, R. G. M. et al. Productivity of soybean in management zones with application of different sowing densities. **Ciência Rural**, v. 48, n. 12, p. 1–9, 2018.

CÓRDOBA, M. A. et al. Protocol for multivariate homogeneous zone delineation in precision agriculture. **Biosystems Engineering**, v. 143, p. 95–107, 2016.

DAVIES, D. L.; BOULDIN, D. W. A Cluster Separation Measure. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. PAMI-1, n. 2, p. 224–227, 1979.

DERBY, N. E.; CASEY, F. X. M.; FRANZEN, D. W. Comparison of Nitrogen Management Zone Delineation Methods for Corn Grain Yield. **Agronomy Journal**, v. 99, n. 2, p. 405–414, 2007.

DIKER, K.; HEERMANN, D. F.; BRODAHL, M. K. Frequency Analysis of Yield for Delineating Yield Response Zones. **Precision Agriculture**, v. 5, p. 435–444, 2004.

DRAY, S.; LEGENDRE, P.; PERES-NETO, P. R. Spatial modelling: a comprehensive framework for principal coordinate analysis of neighbour matrices (PCNM). **Ecological Modelling**, v. 196, n. 3, p. 483–493, 2006.

DRAY, S.; SAÏD, S.; DÉBIAS, F. Spatial ordination of vegetation data using a generalization of Wartenberg’s multivariate spatial correlation. **Journal of Vegetation Science**, v. 19, n. 1, p. 45–56, 2008.

GAVIOLI, A. Módulos computacionais para seleção de variáveis e análise de agrupamento para definição de zonas de manejo. (Tese). Universidade Estadual do Oeste do Paraná, 2017.

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. 3. ed. Upper Saddle River: Pearson Prentice Hall., 2008.

GUASTAFERRO, F. et al. A comparison of different algorithms for the delineation of management zones. **Precision Agriculture**, v. 11, n. 6, p. 600–620, 2010.

HAGHVERDI, A. et al. Perspectives on delineating management zones for variable rate irrigation. **Computers and Electronics in Agriculture**, v. 117, p. 154–167, 2015.

JAVADI, S. H.; GUERRERO, A.; MOUAZEN, A. M. Clustering and smoothing pipeline for management zone delineation using proximal and remote sensing. **Sensors**, v. 22, n. 2, p. 1–20, 2022.

KAZAMA, E. H. et al. Methodology for selective coffee harvesting in management zones of yield and maturation. **Precision Agriculture**, v. 22, n. 3, p. 711–733, 2021.

MACQUEEN, J. Some methods for classification and analysis of multivariate observations. **Proceedings of the Fifth Berkeley Symposium on Mathematics**, p. 281-296, 1967.

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. 1–7, 2022.

PERALTA, N. R. et al. Delineation of management zones to improve nitrogen management of wheat. **Computers and Electronics in Agriculture**, v. 110, p. 103–113, 2015.

PING, J. L.; DOBERMANN, A. Creating spatially contiguous yield classes for site-specific management. **Agronomy Journal**, v. 95, n. 5, p. 1121–1131, 2003.

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, 1987.

# EXPERIMENTAÇÃO ON-FARM NO SISTEMA DE AGRICULTURA DE PRECISÃO EM CANA-DE-AÇÚCAR

**CELIA REGINA GREGO<sup>1</sup>; Cristina Aparecida Gonçalves Rodrigues<sup>2</sup>; Eduardo Antonio Speranza<sup>3</sup>; Ariovaldo Luchiar Junior<sup>4</sup>; Carlos César Ronquim<sup>5</sup>**

<sup>1</sup>Eng. Agrônoma, Pesquisadora - Embrapa Agricultura Digital, UNICAMP Universidade Estadual de Campinas - Embrapa, Av. Dr. André Tosello, 209 - Cidade Universitária, Campinas - SP, 13083-886. celia.grego@embrapa.br / (19) 9 8186-0294; <sup>2</sup>Zootecnista, Pesquisadora - Embrapa Territorial, Campinas, SP; <sup>3</sup>Bach. Ciência da Computação, Analista - Embrapa Agricultura Digital, Campinas, SP; <sup>4</sup>Engenheiro Agrônomo, Pesquisador - Embrapa Agricultura Digital, Campinas, SP; <sup>5</sup>Engenheiro Agrônomo, Pesquisador - Embrapa Territorial, Campinas, SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Este trabalho tem como objetivo principal, apresentar a validação da Agricultura de Precisão por meio da experimentação on-farm em área produtiva de cana-de-açúcar da fazenda Santa Helena, em Ibaté, SP. Foi alocado experimento em zonas de manejo com aplicação localizada de insumos para validação da resposta na fertilidade do solo, da produtividade e do teor de Brix da cana-de-açúcar. As zonas de manejo foram úteis para a alocação dos tratamentos do experimento on-farm, aplicando tratamentos com diferentes dosagens e tipos de adubação em condições reais do sistema de produção com a utilização de maquinário e ferramental disponível na usina. Os tratamentos de adubação nas formas sólida e foliar aplicados em faixas, não provocaram efeitos significativos nos atributos do solo e nem da planta. Contudo, independente da zonas de manejo, a adubação sólida com 30 de N kg ha<sup>-1</sup> foi o tratamento que, significativamente, proporcionou maiores teores de macronutrientes do solo e também maior produtividade da cana-de-açúcar. Ciclos subsequentes da cultura no talhão, devem ser avaliados para que a experimentação on-farm possa evidenciar as diferenças entre as zonas de manejo e validar as técnicas de AP para a área de estudo com cana-de-açúcar.

**PALAVRAS-CHAVE:** Zonas de Manejo; Adubação ; Delineamento em faixa

## ON-FARM EXPERIMENTATION FOR PRECISION AGRICULTURE SYSTEM IN SUGARCANE

**ABSTRACT:** The main objective of this work is to present the validation of Precision Agriculture using on-farm Experimentation, conducted within a sugarcane cultivation area at Santa Helena Farm, in the municipality of Ibaté, São Paulo state, Southeastern Brazil. The experiment was carried out within management zones using localized placement of inputs to validate its effect in: soil fertility, sugarcane productivity and Brix value. Different management zones were useful for the appropriate allocation of treatments, i.e. applying treatments with different dosage and types of fertilizers in real cultivation conditions, using the machinery and tools available at the farm. Fertilization treatments using solid and liquid inputs and strip-trials did not achieved significant positive effects on the evaluated soil or plant attributes. However, regardless the management zone, solid fertilization with 30 N kg ha<sup>-1</sup> was the treatment that significantly achieved higher levels of soil macronutrients and sugarcane yield. Subsequent crop life cycles must be evaluated to evidence differences between management zones and validate precision agriculture techniques for the sugarcane study area.

**KEYWORDS:** Management Zones; Fertilizing; band delineation

**INTRODUÇÃO:** A agricultura de precisão (AP), técnica bastante reconhecida e difundida atualmente em áreas agrícolas com diversas culturas, traz benefícios sociais, ambientais e econômicos. Segundo Molin et al. (2015) a AP resulta no manejo localizado de adubação para gerar economia da dose aplicada, aumento da eficiência de uso dos fertilizantes e diminuição dos impactos ambientais. No entanto, não poucos os trabalhos que apresentam estudos de validação da aplicação dessa técnica. A experimentação dita on-farm, ou seja, na fazenda, pode ser de grande utilidade para essa validação. Para tanto, é realizada a experimentação em condições reais do sistema de produção, adotando um delineamento de execução da pesquisa dentro da fazenda, onde são desenvolvidas, adaptadas e validadas estratégias de manejo sítio específico. Segundo

Shiratsuchi et al. (2014), a experimentação “on farm” consiste na definição de parcelas estabelecidas principalmente dentro das zonas diferenciadas de manejo, conforme disponibilidade de recursos e equipamentos do produtor, dentro de uma área de cultivo agrícola, para que sejam avaliadas diferentes taxas de aplicação, com repetições, em intervenções como plantio (população) e adubação. Segundo Caldwell (1987), os ensaios on-farm podem ser exploratórios, quando pouco é conhecido sobre o efeito do tratamento, de refinamento que são conduzidos na fazenda e geralmente focam em efeitos quantitativos para mostrarem os melhores tratamentos dos ensaios sítio específicos e por último os de validação onde se compara novas intervenções com as práticas já utilizadas pelo agricultor. Em todos os casos, segundo Piepho et al. (2011), é importante adaptar sobre o desenho do experimento e análise dos resultados no âmbito da agricultura de precisão. Os resultados dos experimentos on-farm devem ser utilizados para identificar as melhores opções de manejo para a área em que foram gerados. Bramley et al. (2006), ressaltam que é importante responder ao agricultor no que ele pode modificar em relação as técnicas de manejo no futuro para aplicar os novos conhecimentos a partir dos resultados obtidos na experimentação on-farm. Bramley et al. (2006) também concluem que a hipótese pode não ser validada com os primeiros resultados pois o efeito dos tratamentos pode variar de ano para ano, por isso resultados conclusivos podem não surgir no primeiro ano de ensaio on-farm. Contudo, espera-se que a experimentação on-farm conduzida adequadamente, possa validar a AP para a cana-de-açúcar, trazer ganhos econômicos e benefícios ambientais para o produtor ou para a usina, pois podem indicar significativamente qual o real ganho produtivo da planta dentro de cada zona de manejo de acordo com a capacidade de aplicação dos insumos do produtor de forma localizada e com doses precisas dentro do talhão da cana-de-açúcar. Dentro desta abordagem, este trabalho visa validar a agricultura de precisão aplicada na cultura da cana-de-açúcar em área da Fazenda Santa Helena, considerando a experimentação em condições reais do sistema de produção “on farm” com aplicação de tipos de adubação e dosagens em cobertura.

**MATERIAIS E MÉTODOS:** A área de estudo compreende um talhão cultivado com cana-de-açúcar com aproximadamente 15 hectares numa área em Ibaté, SP, arrendada pela Usina Santa Cruz. A cultivar foi a Sweet 9005HP do CTC, e a avaliação foi realizada em cana soca no quarto ano de produção (safra 2020/2021) para intervenção e validação com experimentação “on-farm”. O ambiente de produção foi classificado considerando a pedologia como BC, segundo Prado (2013). Os mapas de monitoramento das diferentes variáveis de solo e da cultura, realizados a campo nos anos de 2018 a 2019, permitiram identificar, por meio de algoritmos de agrupamento, duas regiões com variabilidades distintas dentro do talhão gerando duas zonas de manejo (ZMs) (SPERANZA et al., 2019). Esse foi o primeiro passo para viabilizar a experimentação “on-farm”. Foi implantado experimento de adubação para aplicação localizada em cobertura variando as doses dos insumos dentro de cada zona de manejo de forma otimizada para facilitar a aplicação. O delineamento experimental foi definido considerando as necessidades e manejos da usina, sendo aplicados mecanicamente cinco tratamentos de adubação sólida e foliar (T1 – testemunha; T2 - adubação sólida 30 kg de N ha<sup>-1</sup>; T3 –adubação foliar 3 l de fonte de N, B, Zn, Mg ha<sup>-1</sup>; T4 – adubação foliar 1,5 l de fonte de N, B, Zn, Mg ha<sup>-1</sup>; T5 - adubação sólida 30 kg de N ha<sup>-1</sup> e adubação foliar 3 l de fonte de N, B, Zn, Mg ha<sup>-1</sup>) conforme a Figura 1. A adubação sólida foi realizada 3 meses após colheita do ciclo anterior da cultura e a adubação líquida foi realizada após 4 meses da adubação sólida. Os tratamentos foram aplicados em faixas de 18 metros de largura contemplando 12 linhas da cultura com 650 m de comprimento. Análises de solo para fins de fertilidade, para produtividade e teor de Brix, foram realizadas em cada zona de manejo e em cada tratamento, eles foram submetidos a análise estatística para análise e validação da melhoria de processo. Foi realizada análise estatística ANOVA, com delineamento em blocos casualizados e em faixa no software R, utilizando o teste F de Fisher-Snedecor (Fisher, 1922). As médias seguidas de letras diferentes, minúsculas nas linhas, indicam diferença estatística a 5% de probabilidade entre os tratamentos e a ausência de letras não indicaram diferença estatística.

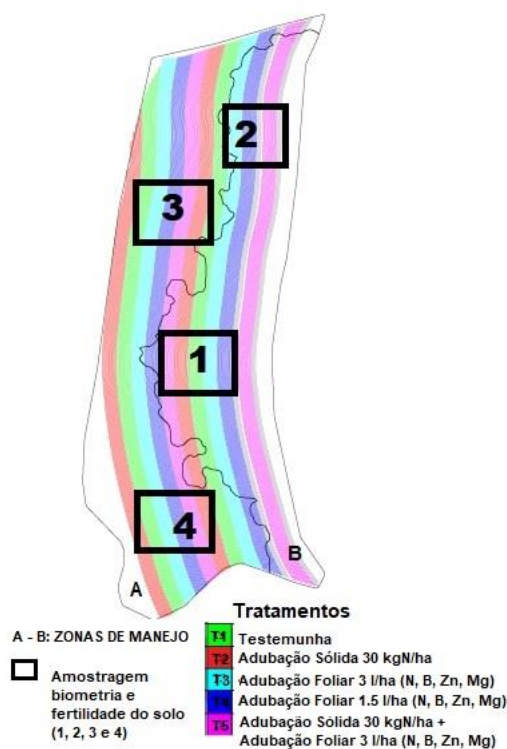


Figura 1. Aplicação dos cinco tratamentos em faixas no ensaio on-farm na cultura da cana-de-açúcar distribuídos em duas posições dentro de cada uma das ZM (A e B).

**RESULTADOS E DISCUSSÃO:** Foram testados tratamentos relacionados a adubação principalmente de nitrogênio na forma sólida em cobertura e líquida, o que se justifica pois o nitrogênio é um dos elementos mais exigidos na cultura da cana-de-açúcar por promover alongamento dos entrenós da cana, que afeta diretamente a produtividade (Penatti, 2013). De acordo com os resultados da análise estatística, as duas zonas de manejo não alteraram significativamente os atributos do solo e a produtividade da cana com adubação sólida e foliar nas diferentes doses. Speranza et al (2019) também não encontraram diferenças entre ZM considerando a produtividade da cana-de-açúcar e a hipótese foi de que a cultura ainda não havia atingido a maturidade capaz de diferenciar a partir dos índices de vegetação. Bramley et al. (2006) também ressaltam que a experimentação on-farm pode não indicar resultados conclusivos no primeiro ano de ensaio. Portanto, para que as diferenças entre tratamentos pudessem ser melhor evidenciadas, seriam necessárias avaliações em outros ciclos produtivos da cana. Na tabela 1, estão apresentadas as análises estatísticas considerando os tratamentos de aplicações em faixas de insumos e doses nas duas ZM, para os atributos químicos do solo coletados após colheita. Houve diferença significativa entre os tratamentos para os atributos fósforo, magnésio, cálcio, pH, matéria orgânica, Soma de bases, Capacidade de troca Catiônica (CTC) e saturação por bases (V%) e o tratamento que resultou em maiores teores dos macronutrientes foi a adubação na forma sólida com a dose de 30 kg de N ha<sup>-1</sup> seguido da forma líquida (3 l ha<sup>-1</sup>).

Tabela 1. Análise estatística dos tratamentos com adubação na cana-de-açúcar, para os atributos de análise do solo Fósforo resina (mg dm<sup>-3</sup>), Potássio (cmolc dm<sup>-3</sup>), Magnésio (cmolc dm<sup>-3</sup>), Cálcio (cmolc dm<sup>-3</sup>), pH CaCl<sub>2</sub>, Matéria Orgânica (g dm<sup>-3</sup>), Soma de Bases, Capacidade de Troca Catiônica (CTC) e Saturação por Bases (V%). Fazenda Santa Helena, Ibaté, SP.

Adubação	Fósforo	Potássio	Magnésio	Cálcio	pH	Matéria Orgânica	Soma de Bases	CTC	Saturação por Bases
Testemunha	1,096ab	0,61	1,22 a	2,66ab	4,83 ab	24,50 b	4,01 ab	8,18 ab	54,13 ab

Sólida 30kg de N ha <sup>-1</sup>	1,094b	0,36	1,38 a	3,15 a	5,12 a	27,75 ab	4,90 a	8,08 bc	60,52 a
Foliar 3 l de fonte de N, B, Zn, Mg ha <sup>-1</sup>	1,127ab	0,67	1,03 ab	2,37 bc	4,63 b	27,50 a	4,07 ab	9,07 a	43,20 b
Foliar 1,5 l de fonte de N, B, Zn ha <sup>-1</sup>	1,112ab	0,50	0,78 b	2,11 c	4,53 b	25,75 ab	3,4 b	7,79 bc	43,28 b
Foliar 1,5 l de fonte de N, B, Zn, Mg + sólida ha <sup>-1</sup> 30 kg de fonte de nitrogênio ha <sup>-1</sup>	1,067 c	0,44	1,24 a	2,67 abc	4,86 ab	24,25 b	4,35 ab	7,15 c	59,9 a
Média	1,097	0,519	1,13	2,62	4,81	25,95	4,26	8,097	52,23
Diferença Mínima Significativa (LSD) a 0,05	1,34	0,44	0,41	0,60	0,43	2,85	1,34	0,95	13,78
Coefficiente de variação (CV)	0,022	56,23	23,99	15,21	5,90	7,29	20,87	7,79	17,49

Nos gráficos da figura 2, estão apresentadas a produtividade e teor de Brix da cana-de-açúcar e a análise de significância dos cinco tratamentos. Verifica-se que houve diferença estatística apenas para a produtividade e que o tratamento que resultou em maior produtividade foi o T2 com adubação na forma sólida com a dose de 30kg de N ha<sup>-1</sup>, assim como para os atributos químicos do solo.




Figura 2. Análise estatística para a produtividade (tha<sup>-1</sup>) e teor de Brix (%) da cana-de-açúcar de acordo com os cinco tratamentos para a cana-de-açúcar.

Verifica-se que tanto a adubação foliar quanto a combinação de sólida e foliar não resultaram em melhorias de produtividade, teor de Brix e nem dos atributos da fertilidade do solo. A combinação de adubação foliar e



sólida pode ter fornecido nitrogênio além do necessário para a planta, considerando que o excesso pode não ser absorvido pela planta e sofrer perdas por lixiviação e volatilização, resultando em risco de contaminação ambiental.

**CONCLUSÃO:** O solo e a produção da cana-de-açúcar foram alterados apenas entre os tratamentos de adubação e não entre as ZM. A combinação de adubação foliar mais sólida não trouxe benefícios para a produtividade, teor de Brix e nem para a fertilidade do solo, sendo que a melhor resposta da produtividade da cana foi para a adubação sólida de 30kg de N ha<sup>-1</sup>. Outros ciclos produtivos da cultura devem ser considerados para que a experimentação on-farm possa validar a técnica de agricultura de precisão da cana-de-açúcar para a área de estudo.

#### **AGRADECIMENTOS:**

A equipe da Usina Santa Cruz de Américo Brasiliense, SP pelas discussões e apoio na condução do trabalho.

#### **REFERÊNCIAS**

BRAMLEY, R.; COOK, S.; ADAMS, M.; CORNER, R. Designing your own on-farm experiments: how PA can help. Grains Research & Development Corporation – GRDC, CSIRO Land and Water, 2006, 36p.

CALDWELL, J. **Design techniques for on-farm experimentation.** FSR/E Training units: volume II. Farming Systems Support Project. University of Florida, Gainesville, 1987. 356p.

FISHER, R. A. On the mathematical foundations of theoretical statistics. Philosophical Transactions of the Royal Society of London a: mathematical, physical and engineering sciences. v. 222, i. 594-604, p. 368-368, jan. 1922. Series A. Disponível:  
[http://l.academicdirect.org/Horticulture/GAs/Refs/Fisher\\_1922\\_Estimation.pdf](http://l.academicdirect.org/Horticulture/GAs/Refs/Fisher_1922_Estimation.pdf). Acesso em: 13 jan. 2022.

MOLIN, J.P.; AMARAL, L. R.; COLAÇO, A. F. Agricultura de Precisão. 1 ed. São Paulo:Oficina de Textos, 2015.

PIEPHO, H. P.; RICHTER, C.; SPILKE, J.; HARTUNG, K.; KUNICK, A.; THÖLE, H. Statistical aspects of on-farm experimentation. **Crop & Pasture Science**, v. 62, p. 721-735, 2011.

PENATTI, C. P. Adubação da cana-de-açúcar - 30 anos de experiência. 1. ed. p. 54-83. Brazil: Editora Ottoni. Itu – SP, 2013.

PRADO, H. Pedologia fácil: aplicações em solos tropicais. 4ª. Edição, Piracicaba: 2013, 284 p.

SPERANZA, E. A.; GREGO, C. R.; JORGE, L. A. de C.; RODRIGUES, C. A. G.; LUCHIARI JUNIOR, A.; RONQUIM, C. C.; SANCHES, G. M. Delineamento de zonas de manejo em cana-de-açúcar a partir de atributos do solo e da cultura e imagens georreferenciadas. In: SIMPÓSIO NACIONAL DE INSTRUMENTAÇÃO AGROPECUÁRIA, 4., 2019, São Carlos, SP. Ciência, inovação e mercado: anais. São Carlos, SP: Embrapa Instrumentação, 2019. Editores: Paulino Ribeiro Villas-Boas, Maria Alice Martins, Débora Marcondes Bastos Pereira Milori, Ladislau Martin Neto. SIAGRO 2019. 175-179

# VARIABILIDADE ESPACIAL DE PROPRIEDADES DO SOLO EM SISTEMAS INTEGRADOS

**NICOLLE LAURENTI<sup>1</sup>; JOSIANE RODRIGUES<sup>2</sup>; EDILSON DA SILVA GUIMARÃES<sup>3</sup>; JOSÉ RICARDO MACEDO PEZZOPANE<sup>4</sup>; ALBERTO CARLOS DE CAMPOS BERNARDI<sup>5</sup>**

<sup>1</sup>Engenheira Agrônoma, Mestranda em Agricultura e Ambiente - Centro de Ciências Agrárias, Universidade Federal de São Carlos, UFSCar, Araras - SP. nicollelaurenti2@gmail.com / (16) 9 9791-3353; <sup>2</sup>Doutora em Ciências, Professora - Centro de Ciências Agrárias, Universidade Federal de São Carlos, UFSCar, Araras - SP; <sup>3</sup>Mestre em Matemática, Estatística e Computação Aplicadas à Indústria, Supervisor do Núcleo de Tecnologia da Informação - Embrapa Pecuária Sudeste, São Carlos - SP; <sup>4</sup>Doutor em Física do Ambiente Agrícola, Pesquisador - Embrapa Pecuária Sudeste, São Carlos - SP; <sup>5</sup>Doutor em Agronomia, Pesquisador - Embrapa Pecuária Sudeste, São Carlos - SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** O fornecimento balanceado de nutrientes é fator chave para a intensificação dos sistemas agropecuários e, nesse sentido, as ferramentas de agricultura de precisão podem ser utilizadas a fim de permitir a identificação de zonas homogêneas e heterogêneas em uma determinada área e, conseqüentemente, possibilitando definir estratégias de manejo mais eficientes. Assim, o objetivo do presente trabalho é estudar a variabilidade espacial de atributos do solo numa área que compreende um sistema de integração pecuária-floresta (IPF) e um sistema de integração lavoura-pecuária-floresta (ILPF) da Embrapa Pecuária Sudeste, São Carlos-SP, utilizando para isso o processo de interpolação espacial pelo Inverso da Distância Ponderada. As variáveis analisadas foram: matéria orgânica (MO), capacidade de troca catiônica (CTC), areia, argila (profundidades 0-0,2 e 0,2-0,4 m) e resistividade elétrica (RE) (profundidades 0-0,5, 0-1,0 e 0-2,0 m). Como resultado, foram obtidos valores médios e altos de MO e CTC na área de estudo, o que está associado ao maior depósito de resíduos vegetais e animais no solo. Por sua vez, a partir dos valores obtidos para os atributos físicos, foi possível caracterizar o solo como argiloso e, com relação à RE, notou-se que a mesma cresceu com o aumento da profundidade. A menos da CTC (0-0,2 m), em que os valores obtidos foram superiores no sistema ILPF, para todas as outras variáveis os valores se mantiveram homogêneos nos dois sistemas.

**PALAVRAS-CHAVE:** agricultura sustentável; interpolação espacial; sistemas integrados

## SPATIAL VARIABILITY OF SOIL PROPERTIES IN INTEGRATED SYSTEMS

**ABSTRACT:** The balanced supply of nutrients is a key factor for the intensification of agricultural systems and, in this sense, precision agriculture tools can be used in order to allow the identification of homogeneous and heterogeneous zones in an area and, consequently, making possible to define management strategies more efficient. Thus, the aim of the present work is to study the spatial variability of soil attributes in an area that comprises an integrated livestock-forest system (ILF) and an integrated crop-livestock-forest system (ICLF) of Embrapa Pecuária Sudeste, São Carlos-SP, using the Inverse Distance Weight interpolation. The variables analyzed were: organic matter (OM), cation exchange capacity (CEC), sand, clay (depths 0-0.2 and 0.2-0.4 m) and electrical resistivity (ER) (depths 0-0.5, 0-1.0 and 0-2.0 m). As result, medium and high values of OM and CEC were obtained in the study area, which is associated with the greater deposit of plant and animal residues in the soil. In turn, from the values obtained for the physical attributes, it was possible to characterize the soil as clayey and, with regard to the ER, it was noted that it increased with depth increasing. Except for CEC (0-0.2 m), in which the values obtained were higher in the ICLF system, for all other variables the values remained homogeneous in both systems.

**KEYWORDS:** sustainable agriculture; spatial interpolation; integrated systems

**INTRODUÇÃO:** Nos dias atuais a humanidade se depara com desafios cada vez maiores para a produção de alimentos e produtos de forma compatível com a disponibilidade de recursos naturais e, por esse motivo, são grandes os apelos para que se difunda em todo o mundo o conceito de agricultura sustentável. De acordo com

esse conceito, os agroecossistemas do século XXI devem ser capazes de maximizar a quantidade de produtos agrícolas de alta qualidade e conservar os recursos naturais do sistema (BALBINO et al., 2012) e, nesse sentido, os sistemas integrados surgem como uma estratégia de produção sustentável (MULLER et al., 2015).

Os sistemas de integração lavoura-pecuária-floresta (ILPF) caracterizam-se por agregar atividades agrícolas, pecuárias e florestais numa mesma área, e buscam efeitos de cooperação entre os componentes do agroecossistema, contemplando a preservação ambiental, a valorização do homem e a viabilidade econômica da atividade agropecuária (BALBINO et al., 2012). No Brasil, a utilização dos sistemas integrados tem aumentado como forma de minimizar os riscos das atividades praticadas de forma isolada, assim como para diminuir as áreas de pastagens degradadas, devido à melhoria das propriedades do solo (EMBRAPA, 2021).

No que diz respeito às propriedades do solo, elas podem variar espacialmente em função de fatores intrínsecos, como os de formação do solo, e extrínsecos, como as práticas de manejo, adubação e rotação de culturas, e a compreensão da variabilidade no espaço das propriedades edáficas nos diferentes sistemas produtivos possui potencial para contribuir com o aumento da produtividade e qualidade, economia de insumo e redução do impacto ambiental (CAMBARDELLA; KARLEN, 1999).

Dentro deste contexto, a obtenção e o processamento de informações georreferenciadas de amostras de solo da área de estudo são importantes pois possibilitam, por meio de procedimento de interpolação espacial, gerar mapas relacionados aos sistemas de produção agrícola, o que constitui um aspecto de inquestionável importância, uma vez que os mapas gerados amparam tecnicamente as decisões estratégicas, permitindo observar os pontos mais complexos da área em estudo, comparando-os com o sistema de manejo adotado, seus efeitos ambientais e a produtividade das diferentes culturas (GREGO et al., 2014).

Diante o exposto, o objetivo do presente trabalho é estudar a variabilidade espacial de atributos do solo numa área compreendida por um sistema de integração pecuária-floresta (IPF) e por um sistema de integração lavoura-pecuária-floresta (ILPF) da Embrapa Pecuária Sudeste, São Carlos-SP, utilizando o processo de interpolação pelo Inverso da Distância Ponderada. Com isso, pretende-se contribuir para com as tomadas de decisões que serão feitas sobre essa área, visando definir estratégias de manejo mais eficientes, em especial o uso racional de insumos e a preservação ambiental, assim também como enfatizar os benefícios dos sistemas integrados.

**MATERIAIS E MÉTODOS:** O estudo foi desenvolvido em uma área experimental da Embrapa Pecuária Sudeste, município de São Carlos, São Paulo, Brasil (21°57'S, 47°51'W, 860 m de altitude). O solo da área é classificado como Latossolo Vermelho-Amarelo distrófico com textura argilosa média (CALDERANO FILHO et al., 1998), e o seu clima é tropical (classificação de Köppen: Cwa), com duas estações bem definidas, sendo ela seca de abril a setembro, com temperatura média de 19,9 °C e precipitação média de 250 mm, e úmida de outubro a março, com temperatura média de 23,0 °C e média de precipitação de 1100 mm (PEZZOPANE et al., 2021).

A área experimental está localizada dentro de uma extensão que compreende um sistema de 30 ha que inclui (PEZZOPANE et al., 2019): i) pastagem intensiva de capim Piatã (*Urochloa brizantha*); ii) Integração lavoura-pecuária (ILP), em que um terço da área é renovada anualmente plantando milho consorciado com capim Piatã; iii) Integração lavoura-pecuária-floresta (ILPF) plantado com *Eucalyptus urograndis* (GG100) em fileiras simples com espaçamento de 15 m e distância de 2 m entre árvores; iv) Integração de pastagem-floresta (IPF), com capim Piatã e eucalipto; v) sistema extensivo de capim braquiária (*Urochloa decumbens*). As pastagens são manejadas em sistema rotacionado com 6 dias de pastejo e 35 dias de repouso em épocas de chuvas e secas.

No presente trabalho foram estudados o sistema de integração lavoura-pecuária-floresta (ILPF1 e ILPF2) e o sistema de integração pecuária-floresta (IPF1 e IPF2) da área experimental (Figura 1). As variáveis analisadas na área foram: i) propriedades químicas do solo - matéria orgânica (MO) e capacidade de troca catiônica (CTC); ii) propriedades físicas do solo - argila e areia; e iii) resistividade.




FIGURA 1. Área de estudo, o sistema de integração lavoura-pecuária-floresta (ILPF1 e ILPF2) e o sistema de integração pecuária-floresta (IPF1 e IPF2) da Embrapa Pecuária Sudeste, município de São Carlos, São Paulo, Brasil.

Para a realização das análises químicas e físicas do solo foi feita uma amostragem no período seco (agosto/2021) em cada piquete da área de estudo (cada piquete de 0,5 ha), totalizando 24 amostras georreferenciadas. Para isso foi utilizado o procedimento de amostragem por zonas homogêneas (FLEMING et al., 2000). Neste estudo, cada piquete foi considerado uma unidade homogênea de manejo, como já descrito por Bernardi et al. (2017). As amostragens em cada piquete foram realizadas em duas profundidades: 0-0,2 m e 0,2-0,4 m, visando assim atender à tipificação dos solos atualmente adotada no Zoneamento Agrícola de Risco Climático pelo Ministério da Agricultura (MAPA, 2008), que diz que as amostras devem ser coletadas na camada de 0 a 0,5 m de profundidade. Em cada piquete foram coletas seis sub-amostras para compor uma amostra composta georreferenciada pelo centroide do piquete (Figura 2).




FIGURA 2. Pontos de amostragem para estudo da fertilidade do solo em sistema de integração lavoura-pecuária floresta (ILPF) e em sistema de integração pecuária-floresta (IPF) da Embrapa Pecuária Sudeste, município de São Carlos, São Paulo, Brasil.

As análises das propriedades físicas das amostras de solo foram realizadas a partir dos métodos de análise física de solos do Instituto Agrônomo de Campinas (MARIA et al., 2021), e as análises das propriedades químicas das amostras, por sua vez, foram realizadas a partir dos métodos de análise química para avaliação da fertilidade de solos tropicais do Instituto Agrônomo de Campinas (RAIJ et al., 2001).

Já as medidas de resistividade elétrica do solo foram obtidas com o sensor comercial ARP system® (Geocarta, Paris, França) (Figura 3), em 3 diferentes profundidades, sendo elas: 0-0,5 m, 0-1,0 m e 0-2,0 m. O sensor possui 8 eletrodos no total, em formato de disco com ponta periférica, sendo 2 emissores e 6 receptores de corrente. A coleta foi realizada a cada 0,1 m, com velocidade aproximada de 6 m/s, sendo os dados de resistividade ( $\Omega$  m) registrados para cada profundidade, com as respectivas coordenadas de cada ponto amostrado. No total, para cada profundidade, foram coletados aproximadamente 480.000 dados georreferenciados.



FIGURA 3. Sensor comercial ARP system®.

Todas as variáveis analisadas foram submetidas inicialmente a uma análise exploratória. Nessa etapa inicial, procedeu-se com a construção do boxplot de cada uma das variáveis. Por meio da construção dos boxplots é possível, dentre outras coisas, identificar os *outliers* presentes nos dados (SCHWERTMAN et al., 2004), os quais são caracterizados por se distanciar drasticamente dos demais pontos do conjunto, podendo viesar todo o resultado de uma análise. Após a retirada dos *outliers* dos dados, procedeu-se com o cálculo das seguintes medidas estatísticas: média, desvio padrão, mínimo, máximo, coeficiente de variação e as medidas de curtose e assimetria.

Finalizada a análise exploratória, seguiu-se com o processo de interpolação espacial de cada uma das variáveis, o qual possibilita a criação de mapas, a partir dos quais é possível visualizar a distribuição espacial das variáveis de interesse na área de estudo. Existem vários métodos de interpolação, dentre os quais estão a interpolação pelo inverso da distância ponderada (do inglês, *Inverse Distance Weight - IDW*) e a krigagem, os quais podem ser classificados pela sua natureza determinística e geoestatística, respectivamente. Para realizar a análise geoestatística, entretanto, deve-se utilizar uma amostra com no mínimo de 100 a 150 pontos (SOUZA et al., 2014). Devido ao tamanho amostral considerado nas análises de fertilidade do solo (análises físicas e químicas – total de 24 amostras), o método utilizado no presente trabalho foi a interpolação IDW (WATSON; PHILIP, 1985).

A interpolação IDW produz uma superfície contínua a partir de pontos conhecidos. No método, a ponderação é atribuída de acordo com a distância entre o ponto no qual se quer prever a característica de interesse e os pontos amostrados. Dessa forma, pontos que estão mais distantes têm peso menor e influenciam menos na previsão, enquanto pontos que estão mais próximos têm peso maior e, portanto, têm maior influência na previsão. Esse cálculo é realizado utilizando-se da equação descrita por Mello et al. (2003):

$$z_p = \frac{\sum_{i=1}^n \left( \frac{1}{d_i^p} \times z_i \right)}{\sum_{i=1}^n \left( \frac{1}{d_i^p} \right)},$$

em que  $z_p$  é o valor da variável a ser interpolado,  $z_i$  é o valor da variável do  $i$ -ésimo ponto amostrado,  $d_i$  corresponde à distância euclidiana entre o ponto a ser interpolado e o  $i$ -ésimo ponto amostrado,  $p$  é o valor do expoente a ser considerado no processo de interpolação, e  $n$  representa o número de pontos amostrados.

O expoente  $p$  utilizado no processo de interpolação, atribui alguns efeitos nos resultados e, portanto, sua escolha foi realizada segundo o processo de validação cruzada, tendo por base o menor valor da raiz quadrada do erro médio (do inglês, *Root Mean Square Error - RMSE*), a qual é comumente utilizada para expressar a acurácia dos resultados numéricos (HALLAK; PEREIRA FILHO, 2011). A RMSE é sempre não negativa, e um valor igual a 0 indicaria um ajuste perfeito aos dados, o que quase nunca é alcançado na prática. Dessa

forma, quanto menor o valor da RMSE melhor, o que indica que, no processo de validação, o valor de  $z_p$  que leva ao menor valor da RSME é o valor que deve ser escolhido para realizar a interpolação IDW.

Todas as análises foram desenvolvidas utilizando o *software* estatístico R (R CORE TEAM, 2021).

**RESULTADOS E DISCUSSÃO:** A estatística descritiva de cada um dos atributos do solo, após a retirada dos *outliers* dos dados, estão apresentados nas Tabelas 1 e 2.

TABELA 1. Estatística descritiva dos atributos físicos e químicos do solo em sistema de integração lavoura-pecuária floresta (ILPF) e em sistema de integração pecuária-floresta (IPF) da Embrapa Pecuária Sudeste, município de São Carlos, São Paulo, Brasil.

Medidas Estatísticas	MO*	MO**	CTC*	CTC**	Areia*	Areia**	Argila*	Argila**
Média	49,53	32,00	83,77	63,00	551,00	560,41	339,69	391,58
Desvio Padrão	6,96	5,85	9,81	2,87	24,37	25,30	22,66	34,63
Mínimo	37,50	25,00	64,50	58,00	492,00	504,00	297,00	308,00
Máximo	69,00	46,50	99,50	69,50	581,00	602,00	384,00	445,00
CV (%)	14,05	18,30	11,71	4,56	4,42	4,51	6,67	8,84
Curtose	1,54	0,45	-0,53	-0,57	3,10	2,57	2,25	2,63
Assimetria	0,95	0,93	-0,50	0,25	-0,89	-0,43	-0,17	-0,48

\* Variáveis matéria orgânica (MO), capacidade de troca catiônica (CTC), areia e argila avaliadas na profundidade 0-0,2 m. \*\* Variáveis matéria orgânica (MO), capacidade de troca catiônica (CTC), areia e argila avaliadas na profundidade 0,2-0,4 m.

TABELA 2. Estatística descritiva da resistividade elétrica (RE) do solo em sistema de integração lavoura-pecuária floresta (ILPF) e em sistema de integração pecuária-floresta (IPF) da Embrapa Pecuária Sudeste, município de São Carlos, São Paulo, Brasil.

Medidas Estatísticas	RE (0-0,5 m)	RE (0-1,0 m)	RE (0-2,0 m)
Média	366,78	552,94	929,99
Desvio Padrão	132,07	199,79	317,01
Mínimo	9,03	18,44	96,66
Máximo	727,74	1094,09	1782,50
CV (%)	36,00	36,13	34,08
Curtose	2,75	2,75	2,76
Assimetria	0,16	0,08	0,05

Tendo-se finalizada a análise exploratória, seguiu-se com a interpolação IDW para cada atributo. O valor do expoente  $p$  utilizado na interpolação, bem como os valores da RSME correspondentes, estão apresentados na Tabela 3. Os mapas gerados pelo processo, por sua vez, estão apresentados nas Figuras de 3 a 7.

TABELA 3. Valores do expoente  $p$  utilizado na interpolação pelo inverso da distância ponderada (IDW) e respectivo valor da raiz quadrada do erro médio (RSME) para cada atributo do solo em sistema de integração lavoura-pecuária floresta (ILPF) e em sistema de integração pecuária-floresta (IPF) da Embrapa Pecuária Sudeste, município de São Carlos, São Paulo, Brasil.

Variável	$p$	RSME
Matéria Orgânica (MO) (0-0,2 m)	3	3,70
Matéria Orgânica (MO) (0,2-0,4 m)	1	3,83
Capacidade de Troca Catiônica (CTC) (0-0,2 m)	4	6,68
Capacidade de Troca Catiônica (CTC) ( 0,2-0,4 m )	2	2,32
Areia (0-0,2 m)	2	17,80
Areia (0,2-0,4 m)	4	17,70
Argila (0-0,2 m)	1	20,80
Argila (0,2-0,4 m)	3	25,10
Resistividade Elétrica (RE) (0-0,5 m)	4	8,51
Resistividade Elétrica (RE) (0-1,0 m)	1	10,20
Resistividade Elétrica (RE) (0-2,0 m)	4	11,90

\* Valores de  $p$  escolhidos com base no processo de validação cruzada, tendo por base o menor valor da RSME.

A matéria orgânica tem sido sugerida como um indicador chave da qualidade do solo, considerando sua influência nos demais atributos essenciais para que o solo desempenhe as suas funções (CONCEIÇÃO et al., 2005). Analisando os mapas de matéria orgânica gerados pelo processo de interpolação, observa-se que em ambas as profundidades o teor de matéria orgânica esteve nos intervalos considerados como médios (cor azul) e altos (cor verde) (ALVAREZ VENEGAS et al., 1999), sendo que na superfície a quantidade de matéria orgânica foi superior àquela obtida em subsuperfície, sendo que nesta última não houve variabilidade espacial da característica em estudo e, na primeira, a variabilidade foi baixa (Figura 4). De acordo com Stockmann et al. (2013), a matéria orgânica do solo apresenta em média 58% de carbono orgânico e, segundo Torres et al. (2014), a quantidade de carbono orgânico do solo está diretamente associada à quantidade de material vegetal presente no solo. Além disso, de acordo com Freitas et al. (2011), o teor de matéria orgânica também é influenciado pelos resíduos de animais aportados no solo. Dessa forma, a quantidade de matéria orgânica na área de estudo pode ser justificada devido a maior diversificação e produção de resíduos vegetais e animais trazidas pelos sistemas integrados. Sobre o teor de matéria orgânica ser superior na superfície, isso já era esperado, uma vez que há uma deposição maior de resíduos animais e vegetais na camada superficial do solo (FREITAS et al., 2011).

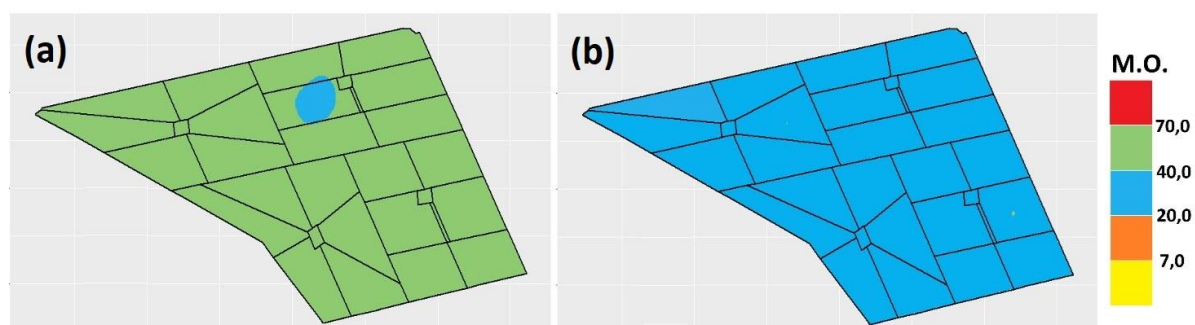




FIGURA 4. Variação espacial de Matéria Orgânica (MO) na área de estudo. (a) Profundidade 0-0,2 m. (b) Profundidade 0,2-0,4 m. Escala de cores nos mapas: amarela – muito baixa; laranja – baixa; azul – média; verde – alta; vermelha – muito alta.

A capacidade de troca catiônica (CTC), por sua vez, representa a capacidade de reter cátions, ou seja, elementos de carga positiva, que são retidos nos colóides no solo, sendo este um dos parâmetros que melhor define a fertilidade do solo (GLÓRIA, 1992). Quanto maior a CTC do solo, maior será a quantidade de cátions que ele pode reter. Através dos mapas gerados pela interpolação espacial, pode-se dizer que a capacidade de retenção de cátions da área de estudo é de média a alta (cor azul e cor verde, respectivamente) (ALVAREZ VENEGAS et al., 1999), sendo que na superfície houve maior retenção de cátions que na subsuperfície, sendo que nesta última não existiu variabilidade espacial da característica em estudo (Figura 5). Esse resultado está diretamente associado aos obtidos para o teor de matéria orgânica na área: de acordo com Baldotto e Baldotto (2018), aumentos nos níveis de matéria orgânica melhoram a fertilidade do solo, uma vez que promovem alterações nas suas propriedades, dentre elas a CTC. A respeito da variabilidade espacial obtida para este atributo na profundidade 0-0,2 m, verifica-se que os maiores teores de CTC foram obtidos, em sua maioria, nas áreas correspondentes aos sistemas ILPF.

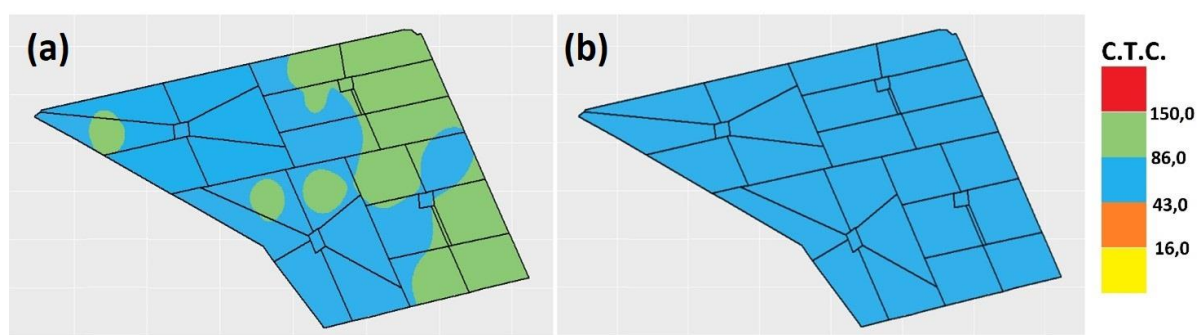


FIGURA 5. Variação espacial da Capacidade de Troca Catiônica (CTC) na área de estudo. (a) Profundidade 0 – 0,2 m. (b) Profundidade 0,2 – 0,4 m. Escala de cores nos mapas: amarela – muito baixa; laranja – baixa; azul – média; verde – alta; vermelha – muito alta.

No que diz respeito aos atributos físicos, notou-se que em ambas as profundidades a quantidade de areia no solo se manteve no intervalo de 150 a 700 (cor azul), o que mostra que não houve variabilidade espacial da característica na área em estudo (Figura 6). Além disso, os valores obtidos em superfície não diferiram dos obtidos em subsuperfície. Já para a quantidade de argila, notou-se a sua variabilidade espacial, embora baixa, nas duas profundidades avaliadas, sendo que os valores obtidos na superfície foram inferiores aos obtidos na subsuperfície (Figura 7). Na profundidade 0-0,2 m, o teor de argila na maior parte da área está localizado no intervalo de 150 a 350 (cor cinza) e, na profundidade 0,2-0,4 m, o teor de argila está, na maior parte da área, no intervalo de 350 a 600 (cor roxa). De acordo com os resultados obtidos para os atributos físicos, a classe textural do solo da área de estudo é, em sua maioria, argilosa (SANTOS et al., 2013). Para ambos os atributos físicos, não foi verificada diferença na distribuição espacial dos valores obtidos entre os sistemas IPF e ILPF.




FIGURA 6. Variação espacial da quantidade de Areia no solo na área de estudo. (a) Profundidade 0-0,2 m. (b) Profundidade 0,2-0,4 m



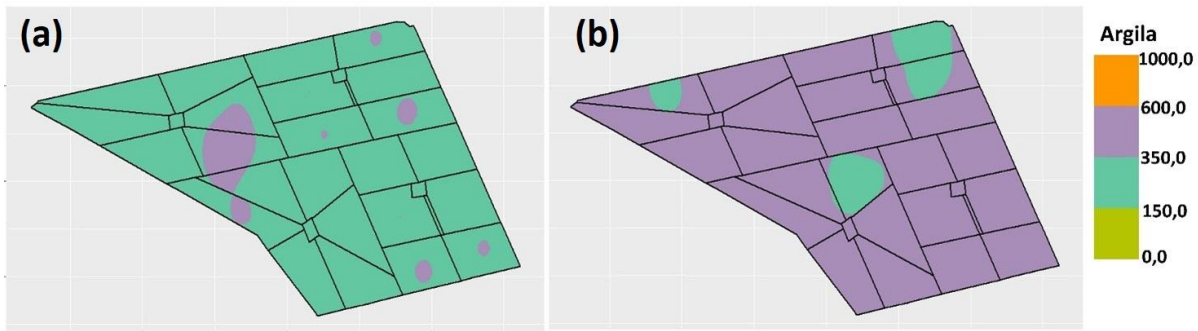


FIGURA 7. Variação espacial da quantidade de Argila no solo na área de estudo. (a) Profundidade 0-0,2 m. (b) Profundidade 0,2-0,4 m.

A resistividade elétrica do solo, por fim, é uma medida de quanto o solo resiste ao fluxo de eletricidade, e ela varia de acordo com a profundidade. A resistividade elétrica está ligada às propriedades intrínsecas do solo, tais como teor de argila, capacidade de retenção de água, pedregosidade e material de origem, bem como às propriedades extrínsecas, tais como estrutura, temperatura e conteúdo de água (SANTOS et al., 2016). Nos mapas gerados pela interpolação, é possível notar que a resistividade na profundidade 0-0,5 m é menor, com o predomínio das cores em verde, diferentemente do que ocorre na maior profundidade, de 0-2,0 m, onde há o predomínio das cores laranja e vermelho (Figura 8). Para este atributo não foi observada uma diferença entre os sistemas ILPF e IPF, uma vez que a distribuição dos valores se manteve homogênea nos dois sistemas, para as três profundidades avaliadas.

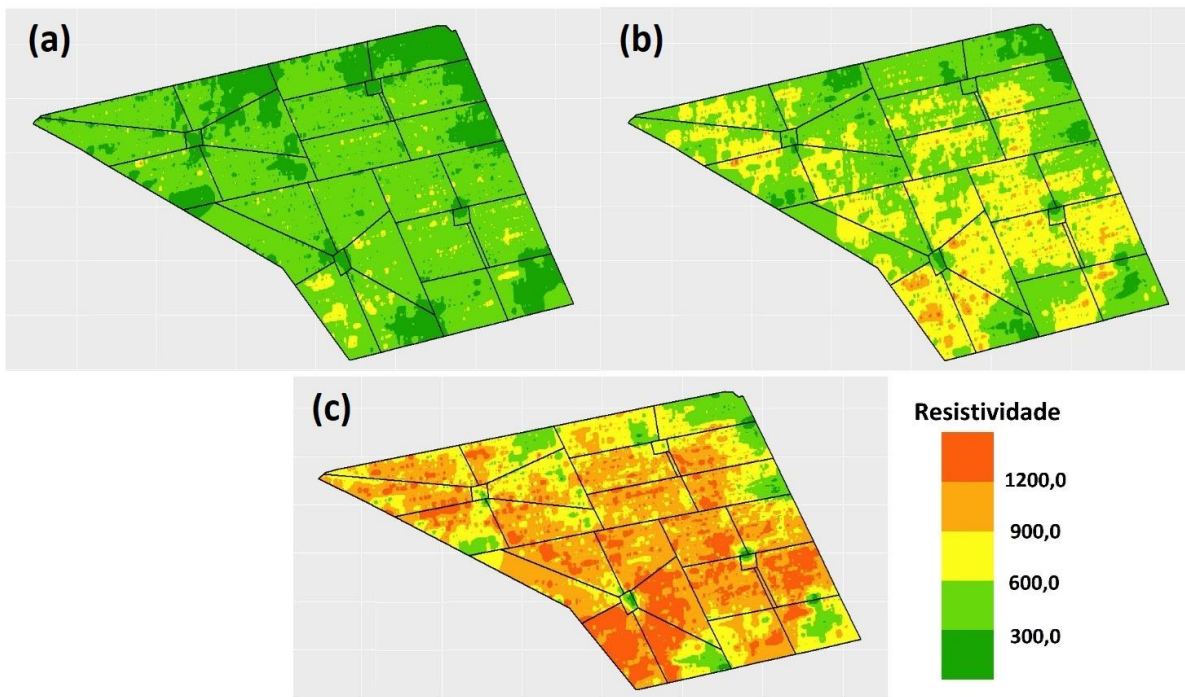


FIGURA 8. Variação espacial da resistividade elétrica do solo na área de estudo. (a) Profundidade 0-0,5 m. (b) Profundidade 0-1,0 m. (c) Profundidade 0-2,0 m.

## CONCLUSÃO:

Em relação às propriedades químicas do solo, foram obtidos valores médios e altos de MO e CTC em toda a área de estudo, o que está associado ao maior depósito de resíduos vegetais e animais no solo, ocasionado pelos sistemas integrados. Para ambas as variáveis, os valores obtidos em superfície foram, em maioria, superiores aos obtidos na subsuperfície, uma vez que há uma deposição maior de resíduos na camada superficial do solo.

Por sua vez, a partir dos resultados obtidos para os atributos físicos, foi possível caracterizar o solo da área de estudo como argiloso. Com relação à quantidade de areia, os valores obtidos foram sempre os mesmos tanto na superfície como na subsuperfície. Já para a quantidade de argila, houve maior depósito da mesma na subsuperfície do solo.

Por fim, para a resistividade elétrica, verificou-se um aumento da resistência do solo conforme houve aumento da profundidade. Na comparação dos sistemas IPF e ILPF, verificou-se que, a menos da variável CTC, na profundidade 0-0,2 m, onde os valores obtidos foram superiores no sistema ILPF, para todas as outras variáveis os valores se mantiveram homogêneos nos dois sistemas integrados, o que ocorreu também para a CTC na profundidade 0,2-0,4 m.

As informações obtidas no presente trabalho serão úteis para definir estratégias de manejo mais eficientes na área de estudo, o que contribuirá para com o aumento da produtividade e qualidade, economia de insumos e redução do impacto ambiental.

Como sugestão para trabalhos futuros, para amostras de tamanho mínimo entre 100 e 150 pontos, a interpolação espacial realizada através da krigagem pode ser utilizada para gerar os mapas de variabilidade espacial dos atributos do solo na área de estudo, sendo esta uma técnica de regressão utilizada para interpolar dados que leva em consideração as características espaciais de autocorrelação de variáveis regionalizadas.

**AGRADECIMENTOS:** Ao Projeto Rural Sustentável – Cerrado, parceria entre BID, Governo do Reino Unido, Ministério da Agricultura, Pecuária e Abastecimento, IABS e ICLF Network Association, por meio da Embrapa.

#### REFERÊNCIAS

- ALVAREZ VENEGAS, V.H.; NOVAIS, R.F.; BARROS, N.F.; CANTARUTTI, R.B.; LOPES, A.S. Interpretação dos resultados das análises de solos. In: RIBEIRO, A.C.; GUIMARÃES, P.T.; ALVAREZ VENEGAS, V.H. (Ed.). **Recomendações para o uso de corretivos e fertilizantes em Minas Gerais**. Viçosa: UFV, 1999. p.25-32.
- BALBINO, L.C.; KICHEL, A.N.; BUNGENSTAB, D.J.; ALMEIDA, R.G. de. Sistemas de integração: o que são, suas vantagens e limitações. In: BUNGENSTAB, D.J. (Ed.). **Sistemas de integração: a produção sustentável**. 2. ed. Brasília, DF: Embrapa, 2012.
- BALDOTTO, M.A.; BALDOTTO, L.E.B. Relationships between soil quality indicators, redox properties, and bioactivity of humic substances of soils under integrated farming, livestock, and forestry. **Revista Ceres**, v.65, p.373-380, 2018.
- BERNARDI, A.C.C.; BETTIOL, G.M.; MAZZUCO, G.G.; ESTEVES, S.N.; OLIVEIRA, P.P.A.; PEZZOPANE, J.R.M. Spatial variability of soil fertility in an integrated crop livestock forest system. *Advances in Animal Biosciences: Precision Agriculture*, v.8, n.2, p.590-593, 2017.
- CALDERANO FILHO, B.; SANTOS, H.D.S.; DA FONSECA, O.O.M.; PRIMAVESI, O.; PRIMAVESI, A.C. **Os solos da Fazenda Canchim, Centro de Pesquisa de Pecuária do Sudeste, São Carlos, SP: levantamento semidetalhado, propriedade e potenciais**. Embrapa CNPS/São Carlos, 1998.
- CAMBARDELLA, C.A.; KARLEN, D.L. Spatial analysis of soil fertility parameters. **Precision Agriculture**, v.1, n.1, p.5-14, 1999.
- CONCEIÇÃO, P.C.; AMADO, T.J.C.; MIELCICZUK, J.; SPAGNOLLO, E. Qualidade do solo em sistemas de manejo avaliada pela dinâmica da matéria orgânica e atributos relacionados. **Revista Brasileira de Ciência do Solo**, v.29, p.777-788, 2005.
- EMBRAPA. **Integração Lavoura-Pecuária-Floresta**. Portal Embrapa, 2021. Disponível em: <https://www.embrapa.br/tema-integracao-lavoura-pecuaria-floresta-ilpf/nota-tecnica>. Acesso em: 15 fev. 2022.

- FLEMING, K.L.; WESTFALL, D.G.; WIENS, D.W.; BRODAHL, M.C. Evaluating farmer defined management zone maps for variable rate fertilizer application. **Precision Agriculture**, v.2, p.201-215, 2000.
- FREITAS, I.C.; FRAZÃO, L.A.; FERREIRA, E.A.; CABRAL, C.M. Como os Sistemas de Integração Lavoura-Pecuária-Floresta influenciam a Dinâmica da Matéria Orgânica do Solo? **Revista Vozes dos Vales**, v.5, p.1-13, 2011.
- GLÓRIA, N.A. Resíduos industriais como fonte de matéria orgânica. In: **Encontro sobre matéria orgânica do solo: problemas e soluções**, Botucatu, 1992. Botucatu: UNESP, Faculdade de Ciências Agrônomicas, 1992. p.129-148.
- GREGO, C.R.; OLIVEIRA, R.P.; VIEIRA, S.R. Geoestatística aplicada a Agricultura de Precisão. In BERNARDI, A.C.C. et al. **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, p.74-83, 2014.
- HALLAK, R.; PEREIRA FILHO, A.J. Metodologia para análise de desempenho de simulações de sistemas convectivos na região metropolitana de São Paulo com o modelo ARPS: sensibilidade a variações com os esquemas de advecção e assimilação de dados. **Revista Brasileira de Meteorologia**, v.26, n.4, p.591-608, 2011.
- MAPA. 2008. Secretaria de Política Agrícola. **Instrução Normativa nº 2, de 9 de outubro de 2008**. Adota, no Zoneamento Agrícola de Risco Climático do Ministério da Agricultura, Pecuária e Abastecimento, as especificações para solos que menciona, e dá outras providências. Disponível em: <<https://www.legisweb.com.br/legislacao/?id=77786>>. Acesso em: 05 mar. 2022.
- MARIA, I.C; COELHO, R.M; ABREU, M.F; CANTARELLA, H. **Métodos de Análise Física de Solos do Instituto Agrônomo de Campinas**. Campinas: Instituto Agrônomo, 2021. 33p.
- MELLO, C.R.; LIMA, J.M.; SILVA, A.M.; MELLO, J.M.; OLIVEIRA, M.S. Krigagem e Inverso do Quadrado da Distância para Interpolação dos Parâmetros da Equação de Chuvas Intensas. **Revista Brasileira Ciência do Solo**, v.27, p.925-933, 2003.
- MULLER, M. D. et al. Sistemas de integração lavoura-pecuária-floresta como alternativa para produção pecuária leiteira sustentável em áreas declivosas. Capítulo 17. In: MARTINS, P.; PICCININI, G.A.; KRUG, E.E.B.; MARTINS, C.E.; LOPES, F.C.F. **Sustentabilidade ambiental, social e econômica da cadeia produtiva do leite: desafios e perspectivas**. Brasília, DF: Embrapa, 2015.
- PEZZOPANE, J.R.M.; BERNARDI, A.C. de C.; BOSI, C.; OLIVEIRA, P.P.A.; MARCONATO, M.H.; PEDROSO, A. de F.; ESTEVES, S.N. Forage productivity and nutritive value during pasture renovation in integrated systems. **Agroforestry Systems**, v.93, p.39-49, 2019.
- PEZZOPANE, J.R.M.; BOSI, C.; BERNARDI, A.C.C.; MULLER, M.D.; OLIVEIRA, P.P.A. Managing eucalyptus trees in agroforestry systems: Productivity parameters and PAR transmittance. **Agriculture, Ecosystems & Environment**, v.312, p.107350, 2021.
- R CORE TEAM (2021). **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.
- RAIJ, B. van; ANDRADE, J.C.; CANTARELLA, H.; QUAGGIO, J.A. **Análise química para avaliação da fertilidade de solos tropicais**. Campinas: Instituto Agrônomo, 2001. 285p.
- SANTOS, H.G. dos; JACOMINE, P.K.T.; ANJOS, L.H.C. dos; OLIVEIRA, V.A. de; LUMBRERAS, J.F.; COELHO, M.R.; ALMEIDA, J.A. de; CUNHA, T.J.F.; OLIVEIRA, J.B. de. **Sistema brasileiro de classificação de solos**. 3. ed. rev. e ampl. Brasília, DF: Embrapa, 2013. 353p.
- SANTOS, D.P.; PITRAT, T.; RABELLO, L.M.; INAMASU, R.Y.; BETTIOL, G.M.; PEZZOPANE, J.R.; BERNARDI, A.C.C. Resistividade elétrica do solo para o estabelecimento de zonas de manejo e em um

sistema de integração lavoura-pecuária-floresta. In: Jornada Científica – Embrapa São Carlos, 8., 2016, São Carlos. **Anais** [...] São Carlos: 2016. p.22.

SCHWERTMAN, N.C.; OWENS, M.; ADNAN, R. A simple more general boxplot method for identifying outliers. **Computational Statistics & Data Analysis**, v.47, n.1, p.165-174, 2004.

SOUZA, Z.M.; SOUZA, G.S.; MARQUES JÚNIOR, J.; PEREIRA, G.T. Número de amostras na análise geoestatística e na krigagem de mapas de atributos do solo. **Ciência Rural**, v.44, n.2, p.261-268, 2014.

STOCKMANN, U.; ADAMS, M.A.; CRAWFORDA, J.W.; FIELDA, D.J.; HENAKAARCHCHI, N.; JENKINS, M.; MINASNYA, B.; MCBRATNEYA, A.B.; COURCELLES, V.R.; SINGHA, K.; WHEELER, I.; ABBOTT, L.; ANGERS, D.A.; BALDOCK, J.; BIRDE, M.; BROOKES, P.C.; CHENUG, C.; JASTROWH, J.D.; LAL, R.; LEHMANNJ, J.; O'DONNELL, A.G.; PARTON, W.J.; WHITEHEAD, D.; ZIMMERMANN, M. The knowns, know nunknowns and of sequestration of soil organic carbon. **Agriculture, Ecosystems and Environment**, v.164, p.80-99, 2013.

TORRES, C.M.M.E.; JACOVINE, L.A.G.; OLIVEIRA NETO, S.N.; BRIANEZI, D.; ALVES, E.B.B.M. Sistemas Agroflorestais no Brasil: Uma abordagem sobre a estocagem de carbono. **Pesquisa Florestal Brasileira**, v.34, p.235-244, 2014.

WATSON, D.F.; PHILIP, G.M. A Refinement of Inverse Distance Weighted Interpolation. **Geoprocessing**, v.2, p.315-327, 1985.

# DESENVOLVIMENTO DE UM PLUGIN PARA INTERPOLAÇÃO POR KRIGAGEM ORDINARIA E MACHINE LEARNING NO QGIS

GUSTAVO WILLAM PERIERA<sup>1</sup>; DOMINGOS SÁRVIO MAGALHÃES VALENTE<sup>2</sup>; DANIEL MARÇAL DE QUEIROZ<sup>3</sup>; ANDRE LUIZ DE FREITAS COELHO<sup>4</sup>

<sup>1</sup>Ciência da Computação, Professor - IFSUDESTE-MG, IFSUDESTE-MG, Muriaé-MG. gustavo.willam@ifsudestemg.edu.br / ; <sup>2</sup>Engenheiro Agrícola e Ambiental, Professor - Departamento de Engenharia Agrícola/UFV, DEA, Campus da UFV; <sup>3</sup>Engenheiro Agrícola, Professor - Departamento de Engenharia Agrícola/UFV, DEA, Campus da UFV; <sup>4</sup>Engenheiro Mecânico, Professor - Departamento de Engenharia Agrícola/UFV, DEA, Campus da UFV

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Algoritmos de Machine Learning (ML) têm sido utilizados como alternativa aos métodos convencionais e geoestatísticos no mapeamento digital de atributos do solo. Uma vantagem dos algoritmos de ML é a flexibilidade de se utilizar diferentes camadas de informação como covariáveis. No entanto, os algoritmos de ML apresentam muitas variantes que podem dificultar a sua aplicação por usuários finais. Para preencher essa lacuna, o objetivo desse trabalho foi desenvolver o plugin para interpolação por Krigagem e Machine Learning no QGIS. O plugin foi denominado *Smart-Map* e desenvolvido para ser utilizado como complemento no QGIS versão 3.10 ou superior. Comparações de performance entre OK e SVM foram realizadas para grid amostrais com 25, 50, 75, 100 e 141 pontos amostrados. O plugin desenvolvido neste trabalho representa uma alternativa para geração de mapas interpolados por OK e ML diretamente no software QGIS.

**PALAVRAS-CHAVE:** Sistemas de informações geográficas (GIS); Inteligência artificial; Mapeamento de solos

## DEVELOPMENT OF A PLUGIN FOR INTERPOLATION BY ORDINARY KRIGAGE AND MACHINE LEARNING IN QGIS

**ABSTRACT:** Machine Learning (ML) algorithms have been used as an alternative to conventional and geostatistical methods in the digital mapping of soil attributes. An advantage of ML algorithms is the flexibility of using different layers of information as covariates. However, ML algorithms have many variants that can make their application difficult by end users. To fill this gap, this work aimed to develop the plugin for interpolation by Kriging and Machine Learning in QGIS. The plugin was called Smart-Map and developed to be used as a complement in QGIS version 3.10 or higher. Performance comparisons between OK and SVM were performed for sample grids with 25, 50, 75, 100 and 141 sampled points. The plugin developed in this work represents an alternative for generating maps interpolated by OK and ML directly in QGIS software.

**KEYWORDS:** Geographic information systems (GIS); Artificial intelligence; Soil mapping

**INTRODUÇÃO:** O mapeamento digital dos atributos do solo fornece informações para aplicação de insumos agrícolas a taxas variadas (MALLA et al., 2020). Entretanto, a eficácia da aplicação depende da qualidade final dos mapas que são, normalmente, obtidos por interpolação com base em amostras georreferenciadas. Quanto maior a densidade amostral, melhor será a qualidade final do mapa, no entanto, maiores serão os custos com amostragens para a geração dos mapas. Em um sistema de amostragem economicamente viável, diferentes métodos de interpolação podem ser utilizados, incluindo o método geoestatístico de Krigagem Ordinária (OK), muito popular no mapeamento digital de solo (VERONESI; SCHILLACI, 2019). Entretanto, uma desvantagem da OK é a necessidade de grandes quantidades de pontos amostrais para modelagem da semivariância (POULADI et al., 2019; WEBSTER; OLIVER, 1992).

Recentemente, com o grande volume de informações geradas nos campos de produção, técnicas de Machine Learning (ML) têm sido utilizadas como alternativa à OK para mapeamento digital de atributos do solo

(HENGL et al., 2018; SEKULI et al., 2020). Os algoritmos de ML procuram descobrir e quantificar padrões entre os dados disponíveis para fazer previsões. Diversos modelos que utilizam algoritmos de ML para previsão e mapeamento de atributos de solos têm sido desenvolvidos (HENGL et al., 2018; KHALEDIAN; MILLER, 2020; LIAKOS et al., 2018). No entanto, para implementar os modelos de ML para mapeamento digital é necessário o domínio de linguagens de programação. Para o desenvolvimento de aplicações utilizando ML, além do conhecimento das linguagens de programação, diversas camadas de dados devem estar disponíveis, como por exemplo: variáveis ambientais e climáticas, dados de sensores de solo e planta, imagens de satélites, mapas de produtividade, modelo digital de elevação, dentre outras.

Conforme exposto, uma ferramenta computacional que facilite o uso de técnicas de ML no mapeamento digital poderá auxiliar os usuários de softwares de sistemas de informações geográficas (SIG). Dentre estes softwares, o QGIS (QGIS DEVELOPMENT TEAM, 2018) é *open-source*, tem interface amigável e uma comunidade ativa de desenvolvedores e usuários. Programas de computadores gratuitos estão disponíveis para Krigagem Ordinária, como o Vesper (WHELAN; MCBRATNEY; MINASNY, 2002), SGeMS (REMY; BOUCHER; WU, 2009) e KrigMe (VALENTE et al., 2012). Entretanto, nenhum deles estão disponíveis como complemento (plugin) do QGIS. Dada a potencial aplicação de ML e a necessidade de integrar o QGIS a um sistema de mapeamento digital de atributos do solo, esse trabalho teve como objetivo o desenvolvimento de um complemento (plugin) para o QGIS para mapeamento digital utilizando OK e ML como métodos interpoladores. O plugin desenvolvido foi denominado *Smart-Map*.

**MATERIAIS E MÉTODOS:** Um estudo de caso para avaliação do *Smart-Map* foi conduzido em uma área localizada no município de Araçuaia (20°42'32" S e 42°34'17" W), região sudeste do estado de Minas Gerais, Brasil (Figura 1). Essa área possui aproximadamente 20,2 ha e é cultivada com café (*Coffea Arábica L.*), altitude média 904 m, relevo montanhoso e o solo predominantemente classificado como Latossolo Vermelho-Amarelo Distrófico (LVAd) de acordo com a classificação atualizada da Embrapa Solos (SANTOS et al., 2018).

Nesta área foram coletados 141 pontos amostrais. No presente trabalho, para efeito de análise da performance dos métodos de interpolação, foram utilizados os seguintes atributos de solos: Fósforo (P), Potássio (K<sup>+</sup>), Cálcio (Ca<sup>+2</sup>), Magnésio (Mg<sup>+2</sup>). A Tabela 1 apresenta as estatísticas descritivas desta área. Os dados foram disponibilizados por (VALENTE et al., 2012).

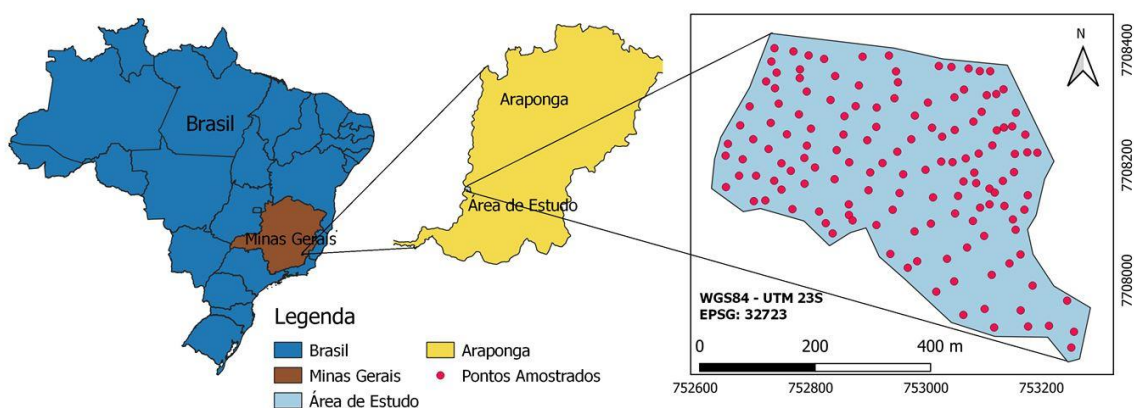


Figura 1: Localização geográfica da área de estudo e distribuição dos pontos amostrais em Araçuaia, Sudeste de Minas Gerais, Brasil.

Tabela 1: Estatística descritiva dos atributos do solo na área de estudo (VALENTE et al., 2012).

Atributo	Unidade	Média	Desvio Padrão	Valor Mínimo	Valor Máximo	CV (%)
P <sup>(1)</sup>	(mg dm <sup>-3</sup> )	4,36	17,20	1,10	22,10	57,90
K <sup>+</sup> <sup>(2)</sup>	(mg dm <sup>-3</sup> )	89,21	32,06	17,00	165,00	35,94
Ca <sup>2+</sup> <sup>(3)</sup>	(cmolc dm <sup>-3</sup> )	2,70	1,20	0,43	9,22	44,66
Mg <sup>2+</sup> <sup>(4)</sup>	(cmolc dm <sup>-3</sup> )	1,21	0,48	0,21	3,71	39,52

<sup>1/</sup> P, Fósforo; <sup>2/</sup> K<sup>+</sup>, Potássio; <sup>3/</sup> Ca<sup>2+</sup>, Cálcio; <sup>4/</sup> Mg<sup>2+</sup>, Magnésio.

Para se realizar a interpolação em diferentes condições de dependência espacial e densidade amostral, foram gerados diferentes grids de amostragens a partir dos grids originais. No presente estudo de caso foram definidos os grids de amostragem com densidades de: 25, 50, 75, 100 pontos, a partir do grid original de referência de 141 pontos. A partir dos grids de amostragem gerados realizou-se a interpolação para cada um dos quatro atributos do solo. Dessa forma, obteve-se os mapas interpolados para cada atributo e grid amostral. Os mapas interpolados foram gerados utilizando os métodos OK e SVM. Na área de estudo foi definido um grid com células de tamanho 5 x 5 m, totalizando 7.860 pontos interpolados.

A dependência espacial dos atributos de solo analisados na área foi calculada de acordo com o Índice de Moran univariado. O Índice de Moran é um indicador útil para analisar a autocorrelação espacial de variável ambiental. Seu valor varia entre -1 (autocorrelação espacial negativa perfeita) e +1 (autocorrelação espacial positiva perfeita), e o valor 0 indica que não há autocorrelação.

Os critérios de comparação utilizados para medir o desempenho entre os métodos foi a Raiz Quadrada do Erro Quadrático Médio (RMSE) da validação cruzada *leave-one-out cross-validation (LOOCV)* (CELISSE; ROBIN, 2008).

O método *LOOCV* foi aplicado para os dois métodos de interpolação, OK e SVM. Após predição de todos os pontos do grid amostral pelo método *LOOCV*, foram calculados os valores de RMSE entre os valores preditos e os valores observados.

O RMSE é um valor absoluto que está na mesma unidade do atributo interpolado, descreve o erro do modelo, o que significa quão próximos os valores previstos estão dos valores reais, para isso utiliza a raiz quadrada da soma dos quadrados dos resíduos.

*Smart-Map* foi registrado no Instituto Nacional de Propriedade Industrial (INPI, Ministério da Economia, Brasil, BR 51 2021 000002-1). A última versão pode ser encontrada no GitHub (<https://github.com/gustavowillam/SmartMapPlugin>) ou instalada a partir do repositório de plugins do QGIS ([https://plugins.qgis.org/plugins/Smart\\_Map](https://plugins.qgis.org/plugins/Smart_Map)). Um tutorial completo de como instalar e utilizar o software está disponível em: <https://github.com/gustavowillam/SmartMapPlugin/wiki>. No canal do YouTube: <https://www.youtube.com/c/AgriculturaDigital>, uma série de vídeos podem ser encontrada para auxiliar na instalação e utilização das principais funcionalidades do plugin. A linguagem Python versão 3.7 foi utilizada para o desenvolvimento do software, sendo compatível com os sistemas operacionais macOS, Linux e Windows. A interface gráfica do usuário (GUI) foi projetada utilizando PyQt5 (Riverbank Computer Limited, Dorchester, United Kingdom). O software é um complemento (plugin) para o software QGIS versão 3.10 ou superior.

O plugin desenvolvido permite ao usuário ajustar cinco modelos de semivariogramas teóricos isotrópicos: linear, linear com patamar, exponencial, esférico e gaussiano. Os ajustes dos parâmetros do semivariograma foram calculados com base na minimização da raiz do erro quadrático médio (RMSE). A escolha do melhor modelo foi executada pelo plugin adotando como critério o modelo com o menor RMSE. Para o modelo SVM, os hiperparâmetros (parâmetros ajustados pelo usuário) como C e *gamma* ( $\gamma$ ) foram otimizados a partir de um método sistemático de busca em grade (KESKIN; GRUNWALD; HARRIS, 2019), permitindo assim um ajuste automatizado sem a interferência do usuário. A validação cruzada *k-fold* foi utilizada para se obter os valores ótimos destes hiperparâmetros, sendo seu valor default igual a cinco.



Além da geração de mapas por interpolação, o *Smart-Map* é dotado de um algoritmo para executar análise de agrupamento utilizando o método *fuzzy k-means* (BEZDEK; EHRlich; FULL, 1984). No final do processamento é exibido o mapa de Zonas de Manejo (ZM). Para definir o número ideal de classes pode-se calcular os índices FPI (Índice de Performance Fuzzy) e o NCE (Entropia de Classificação Normalizada) que são calculados quando se executa o plugin. Os índices FPI e NCE são amplamente recomendados na literatura para definir o número apropriado de ZM's (ALBORNOZ et al., 2018; CHEN et al., 2019). Para executar o processo de cluster e definir as ZM's foi utilizado o algoritmo *fuzzy k-means* da biblioteca Python *Scikit-Fuzzy* (WARNER; SEXAUER; UNNIKRIshNAN, 2019). Na Figura 2 é apresentada a GUI para interpolação de mapas por OK e por SVM do *Smart-Map*.

Para interpolar cada ponto do grid foram definidos o raio de busca igual ao alcance obtido pelo semivariograma teórico e o número máximo de vizinhos igual a 16. Para a interpolação por OK, o *Smart-Map* utiliza a biblioteca Python *open source PyKrig* (MUPHY; MULLHER; YURCHARK, 2020), com algumas adaptações em seu código para funcionar no ambiente do QGIS.

Para a interpolação por ML foi implementado no *Smart-Map* o modelo de aprendizado supervisionado “*Support Vector Machine*” (SVM) disponível na biblioteca Python *open source Scikit-Learn* (PEDREGOSA et al., 2011). No modelo SVM foi utilizado o kernel RBF (*Radial Basis Function*). Para a modelagem é necessário construir a matriz X com as *features* e o vetor y com os valores da variável a ser interpolada. Nesse estudo de caso foram interpolados os atributos P, K<sup>+</sup>, Ca<sup>2+</sup> e Mg<sup>2+</sup>.

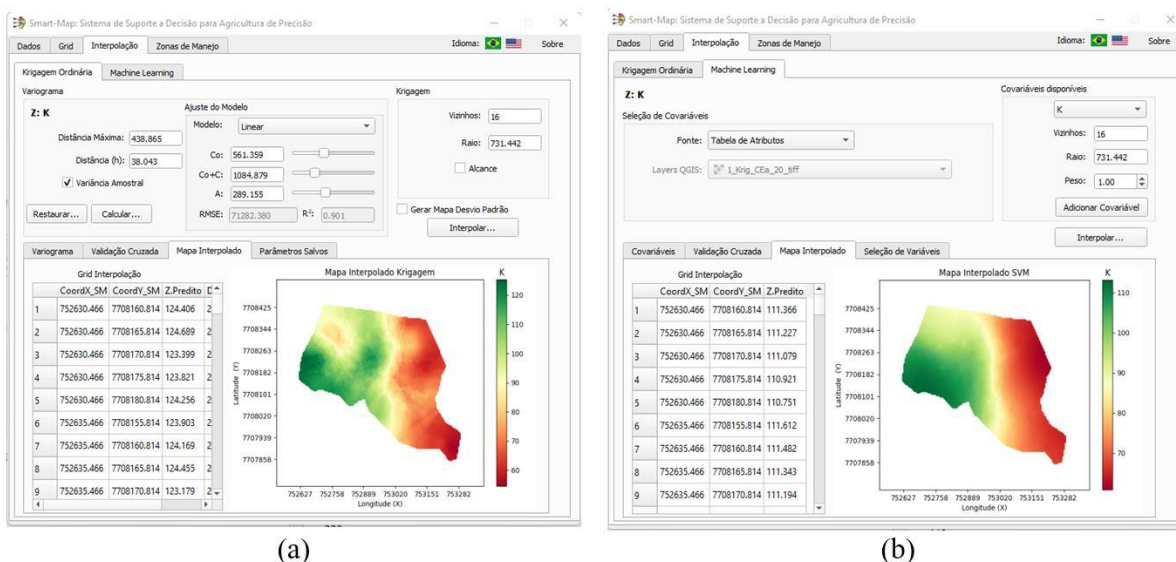


Figura 2: Interface Gráfica do Smart-Map. (a) Interpolação por OK. (b) Interpolação por SVM.

Para treinar o modelo de interpolação pelo método SVM definiu-se uma matriz de treinamento (X). Na matriz X as coordenadas (*coordX* e *coordY*) do ponto e o valor predito do atributo de solo alvo (*idwA*) obtido pelo método IDW, calculado com base nos valores dos 16 vizinhos mais próximos do ponto a ser estimado, foram considerados como variáveis independentes (*features*). O valor conhecido no próprio ponto não entrou no cálculo do atributo *idwA*. Foi gerado assim uma matriz X, em que as *n* linhas representavam os *n* pontos amostrais e três colunas como as variáveis independentes (*coordX*, *coordY*, *idwA*). O valor conhecido do atributo de solo no ponto amostrado (*target\_A*) foi considerado como variável dependente (*y*) do modelo. A Figura 3 representa o conjunto de treinamento do método SVM dividido em variáveis independentes (matriz X) e variável dependente (vetor y).

Especificamente em modelos de ML para predição e mapeamento de atributos de solo podem ser utilizadas como *features* do modelo: coordenadas georreferenciadas, atributos de solos, valores de reflectância obtidos por imagens de satélite, dados de sensores, dentre outros dados que contribuem para a construção do modelo de ML. No entanto, no presente estudo, optou-se por utilizar como *features*, apenas o IDW do próprio atributo de solo a ser interpolado e as informações georreferenciadas dos pontos. A variável dependente (*y*) representa o atributo de solo observado, para o qual se quer predizer seus valores em locais não amostrados. A matriz X

e o vetor  $y$  foram as entradas do conjunto de treinamento do método *SVM*. Os dados de entrada foram padronizados em média zero e desvio padrão um.

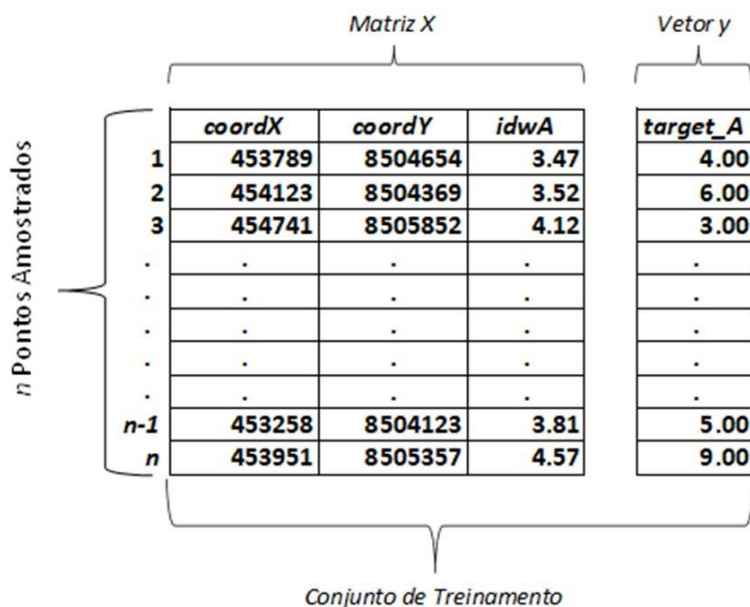


Figura 3: Definição do conjunto de treinamento (Matriz X) e target (Vetor y) do algoritmo SVM.

**RESULTADOS E DISCUSSÃO:** Para realizar a comparação entre os métodos OK e *SVM* escolheu-se uma combinação de pontos amostrais para cada densidade de grid amostral. O Índice de Moran e o pseudo p-valor para os quatro atributos do solo e cinco densidades de grids amostrais da combinação escolhida são apresentados na Tabela 2. O pseudo p-valor foi obtido a partir de 999 permutações entre os pontos do grid amostral com o objetivo de verificar sua significância ao nível de 5% de probabilidade.

Tabela 2: Valores de Índice de Moran e pseudo p-valor calculados para cada conjunto de amostras escolhida, para 5 grids amostrais e 4 atributos de solo na área de estudo.

Atributo	25 Amostras		50 Amostras		75 Amostras		100 Amostras		141 Amostras	
	Moran	p-valor	Moran	p-valor	Moran	p-valor	Moran	p-valor	Moran	p-valor
P <sup>(1)</sup>	0,51	0,016*	0,38	0,011*	0,48	0,047*	0,58	0,068	0,56	0,006*
K <sup>(2)</sup>	0,40	0,073	0,50	0,002*	0,51	0,014*	0,62	0,002*	0,61	0,001*
Ca <sup>2+</sup> (3)	0,35	0,179	0,43	0,030*	0,29	0,042*	0,46	0,341	0,43	0,151
Mg <sup>2+</sup> (4)	0,31	0,288	0,46	0,014*	0,40	0,427	0,58	0,008*	0,52	0,003*

<sup>1/</sup> P, Fósforo; <sup>2/</sup> K<sup>+</sup>, Potássio; <sup>3/</sup> Ca<sup>2+</sup>, Cálcio; <sup>4/</sup> Mg<sup>2+</sup>, Magnésio.

Obs: \*Significância ao nível de 5% de probabilidade.

Para o grid de densidade menor, 25 pontos amostrais, aquele com a menor densidade de pontos, somente o atributo de solo P apresentou dependência espacial significativa. Para o grid de densidade maior, 141 pontos todos os atributos tiveram dependência espacial significativa. Os valores de RMSE foram utilizados como critérios de performance para comparar os métodos OK e *SVM*, a partir da validação cruzada *LOOCV*. A superioridade do *SVM* neste trabalho está relacionada ao fato de o método utilizar os valores interpolados pelo IDW como variável independente no modelo ML. Neste trabalho a terceira *feature* (*idwA*) da matriz X do conjunto de treinamento, foi obtida a partir da interpolação (utilizou-se o interpolador IDW) dos valores da vizinhança da variável dependente ( $y$ ). No modelo *SVM* implementado foram utilizados além das coordenadas X, Y, apenas um atributo como mostrado na Figura 3. Um modelo com um pequeno número de *features* é mais interpretável e a precisão do modelo pode ser melhorada e evitar o risco de sobre ajuste (GREGORUTTI; MICHEL; SAINT-PIERRE, 2017). Outra característica importante dos algoritmos de *Machine Learning* está relacionada a sua capacidade em reconhecimento de padrões. Os algoritmos de ML em especial o *SVM* com

kernel RBF permite que o método produza um plano de separação não linear entre as classes possibilitando a modelagem de fenômenos não lineares que podem ocorrer na distribuição espacial dos atributos de solo (KHALEDIAN; MILLER, 2020; WERE et al., 2015).

Os valores de RMSE para os quatro atributos de solo analisados separadamente, para os métodos OK e SVM podem ser visualizados na Tabela 3. O método *SVM* obteve bons resultados tanto para grid com baixa densidade quanto para o grid com uma densidade maior.

O método *SVM* produziu os menores erros de previsão, exceto para K e Ca<sup>2+</sup> com 25 amostras. No grid amostral com 141 pontos o método *SVM* obteve os menores valores de RMSE para os atributos P, Ca<sup>2+</sup> e Mg<sup>2+</sup>. À medida que se diminui a densidade do grid amostral o método *SVM* tende a ser melhor que o método OK no RMSE. Com o aumento da densidade do grid amostral a diferença entre os dois métodos foi menor, considerando-se os quatro atributos de solo analisados.

Tabela 3. RMSE calculado para os 4 atributos de solo analisados na área de estudo para diferentes números de pontos amostrais.

Atributo	25 Amostras		50 Amostras		75 Amostras		100 Amostras		141 Amostras	
	OK	SVM	OK	SVM	OK	SVM	OK	SVM	OK	SVM
P <sup>(1)</sup>	1,27	1,19	1,71	1,36	2,08	2,01	2,64	1,90	2,37	2,37
K <sup>+</sup> (2)	28,74	30,12	27,41	28,32	30,14	29,55	28,32	27,05	26,61	27,05
Ca <sup>2+</sup> (3)	1,09	1,09	0,93	0,59	1,36	0,86	1,19	0,93	1,20	0,76
Mg <sup>2+</sup> (4)	0,39	0,40	0,40	0,41	0,44	0,34	0,39	0,26	0,45	0,44

<sup>1/</sup> P, Fósforo; <sup>2/</sup> K<sup>+</sup>, Potássio; <sup>3/</sup> Ca<sup>2+</sup>, Cálcio; <sup>4/</sup> Mg<sup>2+</sup>, Magnésio.

Realizou-se a interpolação de todos os quatro atributos do solo, obtendo-se assim os mapas interpolados para os cinco grids de densidades amostrais a partir das amostras selecionadas para cada densidade de grid amostral como apresentado nas Tabelas 2. Os mapas interpolados gerados pelos métodos OK e *SVM* de Potássio (K<sup>+</sup>) para os grids de densidade amostrais de 25 e 141 pontos são apresentados na Figura 4. As concentrações mais altas de K<sup>+</sup> podem ser visualizadas na parte oeste do mapa. Contudo, também foram encontradas diferenças nos padrões espaciais entre os mapas produzidos pelo *SVM* e OK. As transições entre os limites do K<sup>+</sup> foram mais suaves nos mapas de previsão produzidos pelo método *SVM*.

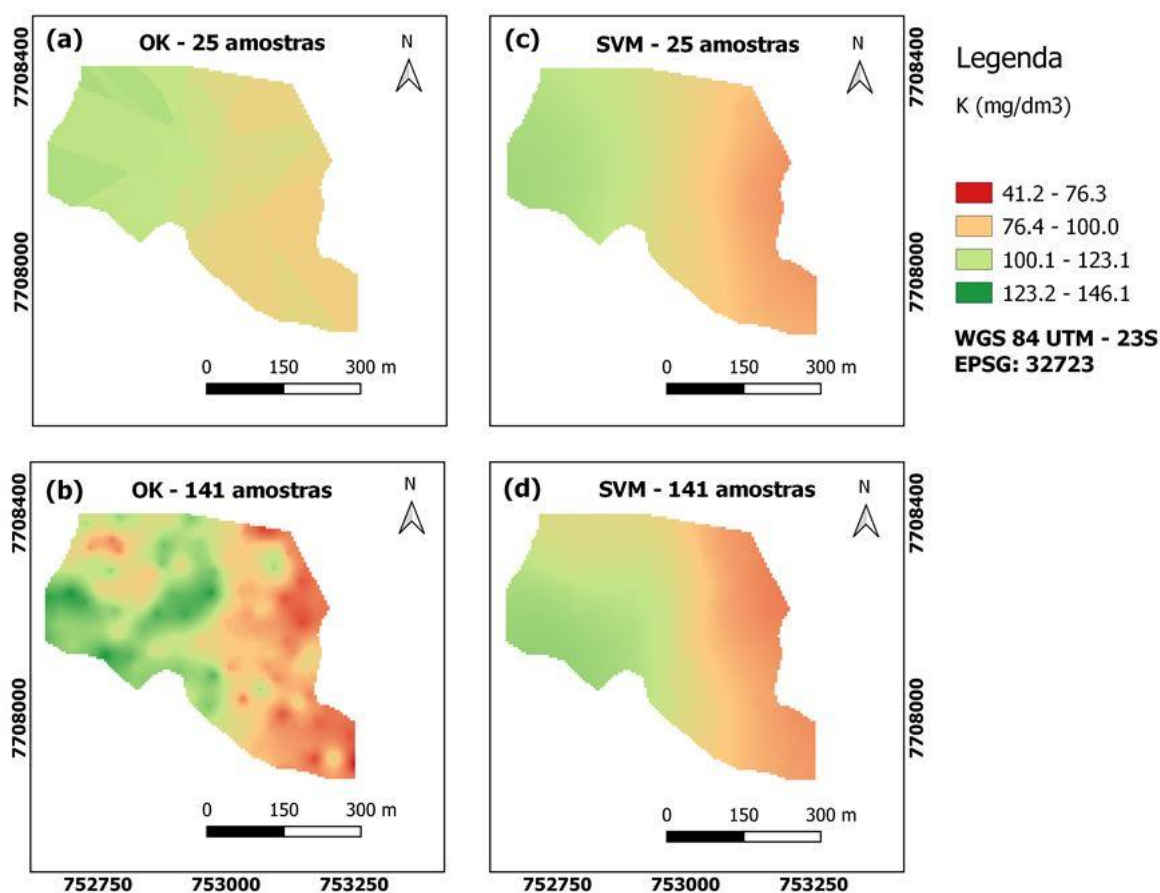


Figura 4: Mapa interpolado de  $K^+$  para os métodos OK e SVM com densidades amostrais de 25 e 141 pontos.

**CONCLUSÃO:** No estudo de caso, foram comparados a interpolação utilizando dois métodos, Krigagem ordinária (OK) e o método de Machine Learning “*Support Vector Machine*” (SVM). Dessa forma, pode-se concluir que o método SVM foi superior ao método OK na predição de atributos químicos do solo nas cinco densidades de pontos dos grids amostrais. Considerando o RMSE, o SVM apresentou o menor erro para a predição dos mapas obtidos por interpolação para os quatro atributos de solos nas cinco densidades amostrais, exceto para o atributo K e  $Ca^{2+}$  com grid de 25 pontos. Em áreas com baixa correlação espacial dos atributos de solos e poucos pontos amostrados, técnicas de ML é uma alternativa ao método OK. Lançado em janeiro/2021, *Smart-Map* contabiliza até a presente data mais de 13.000 downloads ([https://plugins.qgis.org/plugins/Smart\\_Map](https://plugins.qgis.org/plugins/Smart_Map)). Os resultados neste trabalho confirmaram a viabilidade e aplicabilidade de técnicas de ML, em especial o método “*Support Vector Machine*”, para predição e mapeamento de atributos químicos do solo.

#### AGRADECIMENTOS:

Esse estudo foi financiado em parte pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001 e Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

#### REFERÊNCIAS

ALBORNOZ, Enrique M.; KEMERER, Alejandra C.; GALARZA, Romina; MASTAGLIA, Nicolás; MELCHIORI, Ricardo; MARTÍNEZ, César E. Development and evaluation of an automatic software for management zone delineation. *Precision Agriculture*, [S. l.], v. 19, n. 3, p. 463–476, 2018. DOI: 10.1007/s11119-017-9530-9.

- BEZDEK, J. C.; EHRLICH, R.; FULL, W. FCM: the fuzzy c-means clustering algorithm. **Comput. Geosci.**, [S. l.], v. 10, p. 191–203, 1984. DOI: [https://doi.org/10.1016/0098-3004\(84\)90020-7](https://doi.org/10.1016/0098-3004(84)90020-7).
- CELISSE, Alain; ROBIN, Stéphane. Nonparametric density estimation by exact leave-p-out cross-validation. **Computational Statistics and Data Analysis**, [S. l.], v. 52, n. 5, p. 2350–2368, 2008. DOI: 10.1016/j.csda.2007.10.002.
- CHEN, Shichao; WANG, Sufen; SHUKLA, Manoj Kumar; WU, Di; GUO, Xiuwei; LI, Donghao; DU, Taisheng. Delineation of management zones and optimization of irrigation scheduling to improve irrigation water productivity and revenue in a farmland of Northwest China. **Precision Agriculture**, [S. l.], v. 21, n. 3, p. 655–677, 2019. DOI: 10.1007/s11119-019-09688-0.
- GUO, Peng Tao; LI, Mao Fen; LUO, Wei; TANG, Qun Feng; LIU, Zhi Wei; LIN, Zhao Mu. Digital mapping of soil organic matter for rubber plantation at regional scale: An application of random forest plus residuals kriging approach. **Geoderma**, [S. l.], v. 237–238, p. 49–59, 2015. DOI: 10.1016/j.geoderma.2014.08.009. Disponível em: <http://dx.doi.org/10.1016/j.geoderma.2014.08.009>.
- KESKIN, Hamza; GRUNWALD, Sabine; HARRIS, Willie G. Digital mapping of soil carbon fractions with machine learning. **Geoderma**, [S. l.], v. 339, n. November 2017, p. 40–58, 2019. DOI: 10.1016/j.geoderma.2018.12.037. Disponível em: <https://doi.org/10.1016/j.geoderma.2018.12.037>.
- KHALEDIAN, Yones; MILLER, Bradley A. Selecting appropriate machine learning methods for digital soil mapping. **Applied Mathematical Modelling**, [S. l.], v. 81, p. 401–418, 2020. DOI: 10.1016/j.apm.2019.12.016.
- LIAKOS, Konstantinos G.; BUSATO, Patrizia; MOSHOU, Dimitrios; PEARSON, Simon; BOCHTIS, Dionysis. Machine learning in agriculture: A review. **Sensors (Switzerland)**, [S. l.], v. 18, n. 8, p. 1–29, 2018. DOI: 10.3390/s18082674.
- MALLA, Razan; SHRESTHA, Shankar; KHADKA, Dinesh; BAM, Chet Raj. Soil Fertility Mapping and Assessment of the Spatial Distribution of Sarlahi District, Nepal. **American Journal of Agricultural Science**, [S. l.], v. 7, n. 1, p. 8–16, 2020.
- MUPHY, B.; MULLHER, S.; YURCHARK, R. **GeoStat-Framework/PyKrige v1.5.1 (Version v1.5.1)**. [s.l.: s.n.]. DOI: 10.5281/zenodo.3991907.
- PEDREGOSA, Fabian; VAROQUAUX, G.; GRANFORT, Alexandre; MICHEL, Vincent; THIRION, Bertrand. Scikit-learn: Machine Learning in Python. **Journal of Machine Learning Research**, [S. l.], v. 12, n. 1, p. 2825–2830, 2011. DOI: 10.1007/s13398-014-0173-7.2. Disponível em: <http://dl.acm.org/citation.cfm?id=2078195%5Cnhttp://arxiv.org/abs/1201.0490>.
- POULADI, Nastaran; MØLLER, Anders Bjørn; TABATABAI, Salman; GREVE, Mogens H. Mapping soil organic matter contents at field level with Cubist, Random Forest and kriging. **Geoderma**, [S. l.], v. 342, n. October 2018, p. 85–92, 2019. DOI: 10.1016/j.geoderma.2019.02.019. Disponível em: <https://doi.org/10.1016/j.geoderma.2019.02.019>.
- QGIS DEVELOPMENT TEAM. **QGIS Geographic Information System. Open Source Geospatial Found. Proj.** QGIS Development Team. 2018, , 2018.
- REMY, Nicolas; BOUCHER, Alexandre; WU, Jianbing. **Applied Geostatistics with SGeMS**. Cambridge: Cambridge University Press, 2009. DOI: 10.1017/CBO9781139150019. Disponível em: <http://ebooks.cambridge.org/ref/id/CBO9781139150019>. Acesso em: 14 mar. 2021.
- SANTOS, H. G. Dos; CARVALHO JÚNIOR, W.; DART, R. O.; ÁGLIO, M. L. D.; SOUSA, J. S.; PARES, J. G.; FONTANA, A.; MARTINS, A. L. S.; OLIVEIRA, A. P. O. **Sistema Brasileiro de Classificação de Solos**. 5. ed ed. Brasília, DF.

SEKULI?, Aleksandar; KILIBARDA, Milan; HEUVELINK, Gerard B. M.; NIKOLI?, Mladen; BAJAT, Branislav. Random forest spatial interpolation. **Remote Sensing**, [S. l.], v. 12, n. 10, p. 1–29, 2020. DOI: 10.3390/rs12101687.

VALENTE, D. S. M.; QUEIROZ, D. M.; PINTO, Francisco de Assis de Carvalho; SANTOS, Nerilson Terra; SANTOS, Fábio Lúcio. Definition of management zones in coffee production fields based on apparent soil electrical conductivity. **Scientia Agricola**, [S. l.], v. 69, n. 3, p. 173–179, 2012. DOI: 10.1590/s0103-90162012000300001.

VERONESI, Fabio; SCHILLACI, Calogero. Comparison between geostatistical and machine learning models as predictors of topsoil organic carbon with a focus on local uncertainty estimation. **Ecological Indicators**, [S. l.], v. 101, n. December 2018, p. 1032–1044, 2019. DOI: 10.1016/j.ecolind.2019.02.026. Disponível em: <https://doi.org/10.1016/j.ecolind.2019.02.026>.

WARNER, Josh; SEXAUER, Jason; UNNIKRIISHNAN, Aishwarya. **JDWarner/scikit-fuzzy: Scikit-Fuzzy version 0.4.2**. [s.l.: s.n.]. DOI: 10.5281/zenodo.3541386.

WEBSTER, R.; OLIVER, M. A. Sample adequately to estimate variograms of soil properties. **Journal of Soil Science**, [S. l.], v. 43, p. 177–192, 1992. DOI: 10.5771/0038-6073-2013-1-2-191.

WERE, Kennedy; BUI, Dieu Tien; DICK, Øystein B.; SINGH, Bal Ram. A comparative assessment of support vector regression, artificial neural networks, and random forests for predicting and mapping soil organic carbon stocks across an Afromontane landscape. **Ecological Indicators**, [S. l.], v. 52, p. 394–403, 2015. DOI: 10.1016/j.ecolind.2014.12.028. Disponível em: <http://dx.doi.org/10.1016/j.ecolind.2014.12.028>.

WHELAN, Brett M.; MCBRATNEY, Alex B.; MINASNY, Budiman. VESPER 1.5 - Spatial prediction software for precision agriculture. **6th International Conference on Precision Agriculture**, [S. l.], p. 1–14, 2002.



# TÉCNICAS DE SELEÇÃO DE ATRIBUTOS PARA PREDIÇÃO DE PRODUTIVIDADE DA SOJA

Agda Loureiro Gonçalves Oliveira<sup>1</sup>; Joaquim Pedro de Lima<sup>1</sup>; Henrique Oldoni<sup>2</sup>; Luiz Henrique Antunes Rodrigues<sup>1</sup>; Lucas Rios do Amaral<sup>1</sup>

<sup>1</sup>Aluno de doutorado, Doutoranda - FEAGRI, UNICAMP, Campinas-SP. a226160@dac.unicamp.br / (19) 9 8359-5554; <sup>2</sup>Aluno de Pós-Doutorado, Doutorando - Núcleo Interdisciplinar de Planejamento Energético - NIPE, Núcleo Interdisciplinar de Planejamento Energético - NIPE, UNICAMP, Campinas ? SP.

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** A aquisição de dados em agricultura de precisão tem sido cada vez maior. Sendo assim, é importante estabelecer formas de análise que otimizem a extração de conhecimento que muitas vezes está implícito. Uma das alternativas é por meio das técnicas de aprendizado de máquina. No entanto, uma importante etapa de pré-processamento de dados é a seleção de atributos, ainda pouco explorada para fins de previsão de produtividade da soja e identificação de atributos do solo relevantes para sua produção. Nesse sentido, objetivou-se determinar a melhor técnica de seleção de atributos para a previsão da produtividade da soja e avaliar se estas técnicas permitem identificar os atributos de solo de maior importância para a produtividade. Para isso, utilizamos dados de solo, sensoriamento remoto e produtividade de uma área de soja do oeste paulista. Foram testadas as técnicas de seleção de atributos Random Forest, Rrelief e índice de Moran Bivariado. Após a seleção de atributos, a previsão de soja foi realizada com a técnica Random Forest. Dentre as três técnicas de seleção testadas para o conjunto de dados total, o Random Forest foi superior. No entanto, nenhuma das técnicas de seleção de atributos aplicadas ao conjunto de fertilidade do solo se mostrou eficiente para selecionar os atributos mais importantes para a produtividade da soja. Portanto, a técnica de seleção por Random Forest é mais adequada para a seleção de atributos para a previsão da produtividade da soja e as técnicas de seleção de atributos são ineficientes para a identificação de atributos do solo importantes para a produção da soja em áreas de baixo potencial produtivo e com interferência de outros fatores externos ao solo.

**PALAVRAS-CHAVE:** seleção de atributos; mineração de dados; aprendizado de máquina

## ATTRIBUTE SELECTION TECHNIQUES FOR SOYBEAN YIELD PREDICTION

**ABSTRACT:** Data acquisition in precision farming has been increasing. Thus, it is important to establish forms of analysis that optimize the extraction of knowledge that is often implicit. One of the alternatives is through machine learning techniques. However, an important data preprocessing step is the selection of attributes, which has been little explored for soybean yield prediction and identification of soil attributes relevant to soybean production. In this sense, we aimed to determine the best attribute selection technique for soybean yield prediction and evaluate whether these techniques allow the identification of the soil attributes of greatest importance for yield. For this, we used soil, remote sensing and productivity data from a soybean area in western São Paulo. The attribute selection techniques Random Forest, Rrelief and Bivariate Moran index were tested. After the attribute selection, the soybean prediction was performed with the Random Forest technique. Among the three selection techniques tested for the total data set, Random Forest was superior. However, none of the attribute selection techniques applied to the soil fertility set proved efficient for selecting the most important attributes for soybean productivity. Therefore, the Random Forest selection technique is more suitable for the selection of attributes for the prediction of soybean productivity and the attribute selection techniques are inefficient for the identification of soil attributes important for soybean production in areas of low productive potential and with interference from other factors external to the soil.

**KEYWORDS:** attribute selection; data mining; machine learning

**INTRODUÇÃO:** A agricultura de precisão (AP) considera a heterogeneidade de solos e plantas para gerar mapas de prescrição de insumos em taxas variadas (MOLIN; AMARAL; COLAÇO, 2015). Ademais, tecnologias tais como imagens de satélite e condutividade elétrica aparente do solo podem ser utilizadas em



AP para melhorar o desempenho dos mapas de prescrição. Com isso, gera-se enorme quantidade de dados que, quando analisados isoladamente, podem não trazer ganhos de interpretação; entretanto, quando combinados, agregam poder explicativo e são passíveis de serem utilizados para o manejo localizado ou previsão da produtividade dos cultivos. Nesse sentido, técnicas de aprendizado de máquinas podem ser utilizadas para extrair conhecimento sobre os dados coletados.

O pré-processamento dos dados é uma etapa indispensável para aplicação das técnicas de aprendizado de máquina. São destacados como etapas de pré-processamento o reconhecimento de outliers, a integração (PYLE, 1999) e imputação de dados (SONG; SHEPPERD, 2007) e seleção de atributos (RUSS; KRUSE, 2010). Diversas são as técnicas de seleção de atributos, dentre os quais destacam-se os denominados de filtros, como por exemplo o RreliefF, e os métodos wrapper, como é o caso do Random Forest. Além disso, uma técnica para seleção pouco utilizada em aprendizado de máquina para previsão de atributos baseia-se na correlação espacial entre os atributos preditores e o atributo meta por meio do índice de Moran Bivariado (SCHENATTO et al., 2017). Quanto às técnicas, ainda não existe um consenso sobre qual a melhor técnica deve ser utilizada quando o intuito é a previsão de dados de produtividade de culturas.

Além disso, a identificação dos atributos do solo mais limitantes da produtividade da cultura é altamente importante para a tomada de decisão quanto ao manejo da área. No entanto, o uso de seleção de atributos de aprendizado de máquina para esse fim ainda é pouco explorado, sem um entendimento de qual é a técnica mais apropriada. Portanto, objetivou-se com esse estudo determinar a melhor técnica de seleção de atributos para a previsão da produtividade da soja e avaliar se estas técnicas permitem identificar os atributos de solo de maior importância para a produtividade.

**MATERIAIS E MÉTODOS:** A área de estudo (200 ha) pertence à Fazenda Campina, localizada no município de Caiuá, oeste do estado de São Paulo (Latitude 21°38'15" e Longitude 51°54'56"). O solo apresenta textura arenosa, com valores médios de 95 g kg<sup>-1</sup> de argila, 102 g kg<sup>-1</sup> de silte e 803 g kg<sup>-1</sup> de areia na camada de 0,0-0,4 m. O clima da região é do tipo Cwa, subtropical úmido, segundo o sistema de classificação climática Koppen-Geiger, com primavera e verão chuvosos e outono e inverno com índice pluviométrico baixo. Na área foi implementado um sistema de integração lavoura-pecuária (ILP) em novembro de 2018, com cultivo de soja no período de safra e pastagem consorciada na entressafra. A semeadura da soja foi realizada por meio de plantio direto entre os dias 17 e 21 de novembro de 2018, com três distintas variedades: BRS7380 RR semeada no talhão 5, AS3730 IPRO no talhão 6 e NS6700 IPRO nos talhões 7 e 8 (FIGURA 1).

Inicialmente, uma malha de 400 pontos georreferenciados foi estabelecida na área para amostragem de solo na camada de 0-0,20 m (2 amostras por hectare) e destes, 228 pontos para amostragem na camada de 0,20-0,40 m. Tais pontos foram estabelecidos a partir de um planejamento amostral otimizado que visa reduzir as distâncias entre os pontos observados e os locais a serem interpolados, de modo a garantir uma boa distribuição espacial (VAN GROENIGEN et al., 1999). Cada amostra de solo foi composta por quatro subamostras coletadas em um raio de 4 m do ponto georreferenciado. As amostras foram submetidas à caracterização da fertilidade e da granulometria do solo por meio de análises em laboratório para determinação dos atributos: pH em KCl, carbono orgânico total (TOC), fósforo (P), cálcio (Ca), magnésio (Mg) e potássio (K) disponíveis, alumínio (Al), acidez potencial (H+Al), boro (B), cobre (Cu), ferro (Fe), manganês (Mn), enxofre (S), zinco (Zn), areia, silte e argila, seguindo os procedimentos de análises do solo da região (Camargo et al., 2009), com posterior cálculo da capacidade de troca catiônica (CTC) e a saturação por bases (V%).

Dados de condutividade elétrica aparente do solo (CEa) foram obtidos por meio do sensor de indutância eletromagnética EM38-MK2 (Geonics, Canadá) nas camadas de 0-0,38 e 0-0,75 m de profundidade, em passadas de 30 m, com frequência de uma coleta de dado por segundo. Para isso, o sensor foi acondicionado na horizontal em um trenó livre de objetos metálicos, tracionado por um quadriciclo.

Além disso, 100 pontos georreferenciados foram estabelecidos na área de maneira aleatória na área para amostragem da produtividade da soja (FIGURA 1). Esta ocorreu por meio da colheita manual de grãos em 1,0 m linear, seguindo a linha de plantio, em cada um dos 100 pontos. Em seguida, determinou-se a massa e umidade de grãos de cada ponto, para sua correção e padronização em 13% de umidade, e posterior a determinação da produtividade em kg ha<sup>-1</sup>.

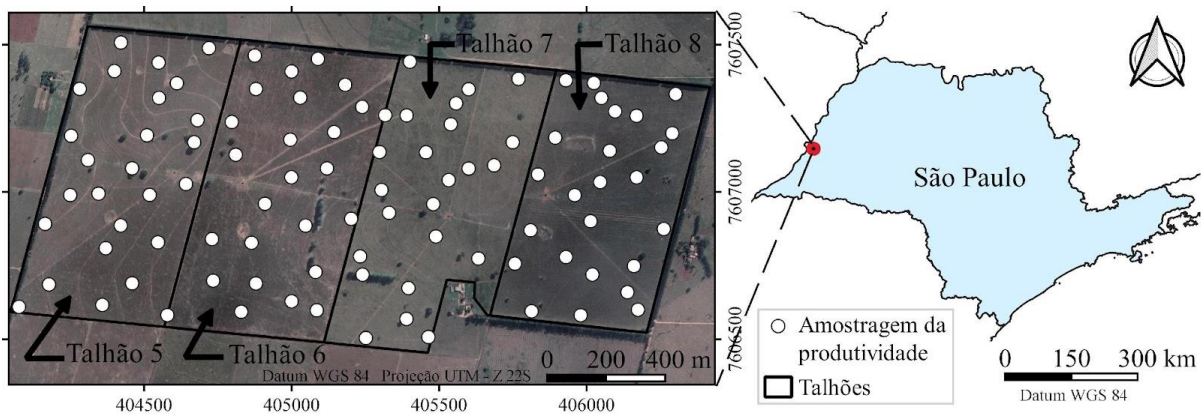


FIGURA 1. Área de estudo com pontos amostrais, distinção de talhões e localização no Estado de São Paulo. Tradução

Sete imagens de sensoriamento remoto do satélite Sentinel 2B, isentas de sombras e nuvens, foram obtidas em sete diferentes datas (1- 14/12/2018, 2- 03/01/2019, 3- 11/01/2019, 4- 21/01/2019, 5- 28/01/2019, 6- 07/02/2019 e 7- 17/02/2019) distribuídas durante o intervalo entre o início do período vegetativo e a maturação fisiológica da cultura da soja. A partir destas imagens, foram calculados os índices de vegetação da diferença normalizada (NDVI), diferença normalizada do vermelho limítrofe 1 (705 nm) e 2 (740 nm) (NDRE1 e NDRE2, respectivamente) e diferença normalizada da água (NDWI). Embora o NDVI possa ocasionar problemas de saturação de seu valor quando o dossel da soja recobre toda a entrelinha, prejudicando a caracterização espacial do vigor da cultura, foi adotado neste estudo por possuir relação com o vigor da planta nos estádios vegetativos menos avançados da cultura. Além disso, calculamos o NDRE para fornecer maior informação a respeito da variabilidade espacial da cultura quando os valores de NDVI encontravam-se saturados. Já o NDWI permite a obtenção de informações sobre a quantidade de água na planta e no solo, o que possibilita compreender a variabilidade espacial da água desde a germinação até a maturação.

A partir de imagem do modelo digital de elevação do sensor PALSAR acoplado ao satélite ALOS, foram derivados os seguintes atributos: curvatura geral (Curv\_G), curvatura horizontal (Curv\_H), curvatura vertical (Curv\_V), elevação (Elev), sombreamento (Hillshade) e declividade (Slope) do terreno.

Diante de que a produtividade da soja foi estabelecida como atributo meta em 100 pontos amostrais (100 observações), todos os demais atributos preditores (total de 79 atributos) foram reduzidos ao mesmo número de observações. Assim, o conjunto de dados total de CEa (densidade amostral elevada), foi reduzido em 100 observações a partir da determinação da média dos dados do interior de buffers com raio de 15 m, alocados em cada um dos 100 pontos de amostragem da soja. Os índices de vegetação e atributos de terreno, obtidos em formato raster, foram também reduzidos em 100 observações, a partir da extração do valor de cada pixel colocalizado com os 100 pontos amostrais. Para os dados de fertilidade do solo da camada de 0-0,20 m, foram extraídos os valores dos pontos coincidentes aos 100 pontos da malha de amostragem da produtividade. Já para os dados de solo da camada de 0,20-0,40 m, devido a não coincidência de parte dos pontos com a malha de amostragem da produtividade, os dados foram extraídos dos mapas interpolados por krigagem.

Valores fora do intervalo de mais ou menos três vezes o desvio padrão foram removidos e dados faltantes foram preenchidos a partir de imputação pelo método dos k vizinhos mais próximos (k-NN) com valor de k igual a 3. Em seguida, os dados foram padronizados para média igual a 0 e desvio padrão igual 1.

Para a seleção de atributos e predições, foi definido o seguinte fluxograma de trabalho (Figura 2): (A) conjunto de dados com todas as informações (Total; 100 observações x 79 atributos preditores) e conjunto de dados apenas com os atributos de fertilidade do solo (Fertility; 100 observações x 44 atributos preditores); (B) Métodos de seleção de atributos aplicados aos conjuntos de dados definidos em A: RRelief, Moran Bivariado e Random Forest, além da não seleção de atributos (No Select); (C) Método de predição Random Forest aplicados aos oito conjuntos provenientes da etapa B. Com isso foram realizadas oito predições, seis advindas dos conjuntos de dados provenientes da seleção de atributos e duas provenientes dos conjuntos sem a seleção de atributos (Total e Fertility).

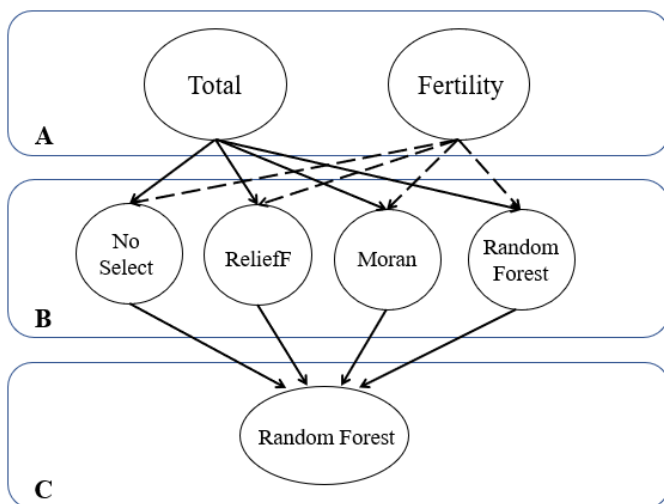


Figura 2. Fluxo de trabalho. Tradução

A seleção de atributos por RReliefF ocorreu de acordo com estratégia adotada por Bocca e Rodrigues (2016), com uso do algoritmo RReliefF de Robnik-Šikonja e Kononenko (1997) na etapa de treino com 10 vizinhos, ranqueamento com correção exponencial, repetição da análise em 10 vezes, ranqueamento e eliminação dos atributos com importância negativa e padronização dos restantes para somar 1. Foram escolhidos os atributos que juntos somaram uma porcentagem de valor explicado  $\geq 90\%$ . A seleção por meio de Moran Bivariado foi realizada de acordo com Schenatto et al. (2017), selecionando os atributos com correlação espacial significativa ( $p\text{-valor} \leq 0,05$ ) com a produtividade da soja e não colineares (GAVIOLI et al., 2019). A seleção de atributos por Random Forest foi realizada a partir da modelagem pela técnica de Random Forest e ranqueamento dos atributos de maior para menor importância ao modelo, com escolha do menor número de variáveis que minimiza o erro médio quadrático da predição.

Para a modelagem do método de predição, os dados foram divididos por sorteio aleatório em treino e teste na proporção 0,75 e 0,25 respectivamente (75 e 25 observações, respectivamente para cada conjunto). A técnica utilizada foi a Random Forest (BREIMAN, 2001), uma vez que vem sendo amplamente utilizada em diversos estudos com superioridade na qualidade de predição diante de diversos outros modelos. Para esta modelagem de predição, foi realizada a otimização dos hiperparâmetros número de árvores (ntree), número de atributos usados para construir a árvores (mtry) e o número de registro por nó (nodesize) para o conjunto de treino, sendo adotados os seguintes intervalos: ntree de 100 a 2.000 árvores; mtry de 1 ao número máximo de atributos por conjunto de dados; e nodesize de 1 a 20 registros por nó.

De posse dos hiperparâmetro otimizados para cada um dos 8 conjuntos de dados, o treinamento dos modelos de Random Forest foi realizado no conjunto de treino e as predições foram realizadas para o conjunto de teste. O procedimento de validação cruzada foi realizado com 5 folds (cv5), obtendo-se como métrica de avaliação preditiva dos modelos, o erro médio absoluto (MAE).

**RESULTADOS E DISCUSSÃO:** Em relação à seleção de variáveis para o modelo preditor com os dados do conjunto Fertility, o RReliefF foi a técnica que selecionou o maior número de variáveis (32 variáveis), seguido por Moran Bivariado (19 variáveis) e RF (10 variáveis). Para esse mesmo conjunto de dados o único atributo selecionado nas três técnicas na camada de 0,00-0,20 m foi a argila, porém na camada de 0,20-0,40 m os atributos selecionados em ambas as técnicas foram potássio, enxofre e argila (Tabela 2).

Tabela 2. Macro e micronutrientes do solo selecionado pelas técnicas RReliefF, Moran Bivariado e Random Forest para o banco de dados apenas com dados de fertilidade (Fertility).

Atributo	pH	TOC	P	Ca	K	Mg	Na	SB	Al	H+Al	CEC	V%	B	Cu	Fe	Mn	S	Zn	Sand	Silt	Clay
----------	----	-----	---	----	---	----	----	----	----	------	-----	----	---	----	----	----	---	----	------	------	------

0.00-0.20 m																				
RReliefF	x	x	x	x	x		x	x			x	x	x	x	x		x	x	x	
Moran Bivariado	x				x	x	x					x	x		x	x	x	x	x	
Random Forest				x									x						x	
0.20-0.40 m																				
RReliefF	x	x	x	x	x	x	x	x		x	x	x	x	x	x	x	x	x	x	x
Moran Bivariado			x	x								x	x		x	x	x			x
Random Forest				x	x			x					x	x		x				x

Na seleção de atributos para o modelo preditor composto do conjunto Total o Relief foi a técnica que selecionou o maior número de variáveis (66 variáveis), seguido pelo Moran Bivariado (25 variáveis) e por fim o RF (20 variáveis) (Tabela 3). Para esse mesmo conjunto de dados os atributos B e Clay foram selecionados por ambas as técnicas para a camada de 0,00-0,20 m, porém para a camada de 0,20-0,40 m os atributos K, Mn e S foram selecionados em ambas as técnicas. Os dados de sensores comumente selecionados para esse conjunto foram NDRE1\_1, NDRE1\_6 e NDRE2\_2 (Tabela 4).

Tabela 3. Macro o micronutrientes do solo selecionados pelas técnicas Rrelief, Moran Bivariado e Random Forest para o banco de dados completo (Total).

Atributos	pH	TOC	P	Ca	K	Mg	Na	SB	Al	H+Al	CEC	V%	B	Cu	Fe	Mn	S	Zn	Sand	Silt	Clay
	0.00-0.20 m																				
RReliefF	x	x			x	x				x			x	x	x	x			x	x	x
Moran Bivariado	x					x	x						x	x		x	x	x	x		x
Random Forest					x								x		x						x
0.20-0.40 m																					
RReliefF	x	x	x	x	x	x	x	x		x	x	x	x	x	x	x	x	x	x	x	x
Moran Bivariado			x	x										x		x	x				x
Random Forest					x	x			x	x	x					x	x			x	

No conjunto de dados Total, o Moran Bivariado apresentou maior número de árvores, no entanto o maior número de atributos por árvore selecionados foram 8 para os dados sem seleção de atributos, ainda assim o maior número de registros por nó foram 17 para o índice de Moran Bivariado. Para o conjunto de dados Fertility o maior número de árvores foi para o Random Forest, com 306 árvores, já o maior número de atributos por árvore e de registros por nó foi para os dados do conjunto Fertility sem seleção de atributos com 3 atributos por árvores e 19 registros por nó respectivamente.

Tabela 4. Seleção dos atributos de relevo, CEa, NDVI, NDRE e NDWI pelas técnicas RReliefF, Moran Bivariado e Random Forest para o banco de dados completo (Total).

Atributo	Curv_G	Curv_H	Curv_V	Elev	Hillshade	Slope	CEa_1	CEa_5	NDVII*
RReliefF	x		x	x	x	x	x	x	

Moran Bivariado	x	x				x			x
Random Forest								x	x
	NDVI2	NDVI3	NDVI4	NDVI5	NDVI6	NDVI7	NDWI1*	NDWI2	NDWI3
RReliefF	x	x	x	x	x	x		x	x
Moran Bivariado									
Random Forest								x	
	NDWI4	NDWI5	NDWI6	NDWI7	NDRE*11	NDRE12	NDRE13	NDRE14	NDRE15
RReliefF	x	x	x	x	x	x	x	x	x
Moran Bivariado	x				x				
Random Forest			x		x				
	NDRE16	NDRE17	NDRE21	NDRE22	NDRE23	NDRE24	NDRE25	NDRE26	NDRE27
RReliefF	x	x	x	x	x	x	x	x	x
Moran Bivariado	x		x	x					
Random Forest	x	x		x					

Os índices de vegetação NDVI e NDWI foram extraídos de sete imagens do satélite Sentinel (NDVI e NDWI de 1 a 7). O mesmo ocorre para o NDRE, no entanto, pela resolução espectral do satélite foram calculados dois índices NDRE (NDRE1 e NDRE2) para as sete imagens utilizadas.

Para o conjunto de dados completo (Figura 3), o único método de predição que apresentou melhora no desempenho em relação ao conjunto de dados sem seleção de atributos, foi a seleção utilizando Random Forest, com um erro médio absoluto de 630 kg ha<sup>-1</sup>. Enquanto no conjunto de dados Fertility, não houve técnica que superou o desempenho dos dados sem seleção de atributos, que obteve um desempenho de 613 kg ha<sup>-1</sup> na predição. Além disso, o modelo que apresentou pior desempenho foi o que levou em consideração os dados completos selecionados pelo Moran Bivariado, com um erro médio absoluto de 711 kg ha<sup>-1</sup>. Por meio da seleção de atributos, o modelo que apresentou melhor desempenho foi o Relief para os dados de fertilidade, com um erro médio absoluto de aproximadamente 624 kg ha<sup>-1</sup>.




Figura 3. Erro médio absoluto (MAE) das predições.

As informações relativas ao relevo, CEa e índices de vegetação em sua maioria não expressaram o comportamento espacial dos atributos do solo, principalmente na camada de 0,00-0,20 m, e da produtividade. Isso fez com que tais informações não fossem suficientes para melhorar o modelo de predição Random Forest. Essa questão fica mais evidente quando é analisada a importância de tais informações para o modelo (dados não apresentados). O desempenho baixo para esse quesito pode ser um indicativo que tais informações adicionais não são capazes de captar a aleatorização da distribuição da urina e fezes pelo gado presente na área antes do cultivo da soja. Dessa maneira, apenas os dados de fertilidade do solo, com ou sem seleção de atributos, apresentaram resultados melhores do que o conjunto de dados completos.

Esse pior desempenho no conjunto de dados Total está relacionado à presença de variáveis redundantes. Ao reduzir o conjunto de dados completo para o conjunto fertilidade, ocorreu eliminação de variáveis redundantes, aumentando o desempenho do modelo de predição. Esse efeito também é verificado nos dados selecionados a partir de Relief e Moran Bivariado que resultou em modelos com melhores desempenhos no conjunto de dados fertilidade do que no conjunto de dados completo. Por outro lado, o Random Forest foi mais robusto à presença de dados redundantes, com melhor desempenho mesmo no conjunto de dados completo.

Ao utilizar as técnicas Moran Bivariado e Relief ocorreu pequena contribuição de cada variável à variação explicada pelo modelo, enquanto a técnica Random Forest apresenta variáveis com maior contribuição. Assim, foi necessário menor número de variáveis para obter quantidade de variância explicada de 90% (dados não apresentados).

A técnica Relief adicionou todas as variáveis até 90%. No conjunto completo essa seleção não foi satisfatória, mas houve melhoria no conjunto fertilidade. Podemos inferir que adicionar algumas propriedades, i.e. NDVI em data que provavelmente ocorre saturação na banda do vermelho, não trouxe benefício aos modelos de predição, mas adicionou ruído e prejudicou a modelagem. De maneira similar, a técnica Moran Bivariado selecionou maior volume de dados em profundidade, mas adicionou variáveis como CEa superficial. Essa adição de variáveis, seja redundante ou com pouca relação com o atributo meta, trouxe dados desnecessários ao modelo. Por outro lado, a técnica Random Forest apresentou melhor resultado ao adicionar os índices de vegetação NDVI, NDWI, NDRE1 e NDRE2 e sensor de CEa na predição. Podemos atribuir essa melhoria às datas dos índices que apresenta relação com estágio fenológico da soja. Os índices NDVI e NDWI escolhidos datam do ciclo vegetativo da soja, em que a umidade (NDWI) do solo possui forte relação com a produtividade, e o NDVI ainda não foi afetado pela saturação no comprimento de onda da banda do vermelho. No monitoramento da produtividade, o índice NDRE se sobressai ao NDVI por apresentar menor variabilidade, sendo mais confiável e apresenta maior correlação com concentração de clorofila na planta (CARNEIRO et al., 2019).

Nesse sentido, se destaca o maior peso na importância dos atributos de fertilidade na camada subsuperficial selecionados por ambas as técnicas de seleção utilizada. Isso reforça a justificativa de que a variabilidade inculca pelo gado não favorece a previsão de produtividade da soja quando a coleta de solo é realizada antes de seu cultivo, dessa maneira sugerimos que a coleta de solo para o planejamento do cultivo de uma lavoura de soja em um SIPA seja realizada antes do estabelecimento da pastagem com o intuito de minimizar esse efeito inicialmente prejudicial análise dos dados da camada superficial do solo. Adicionalmente, ao inserir variáveis que não explicam essa variabilidade do gado, ocorre efeito de redução do desempenho do modelo.

**CONCLUSÃO:** A técnica de seleção por Random Forest é mais adequada para a seleção de atributos para a previsão da produtividade da soja por aprendizado de máquina. As técnicas de seleção de atributos são ineficientes para a identificação de atributos do solo mais importantes para a produção da soja em áreas de baixo potencial produtivo e com interferência de fatores externos ao solo.

#### **AGRADECIMENTOS:**

Ao Prof. Dr. Paulo Sérgio Graziano Magalhães que coordena o projeto “Monitoring integrated crop-livestock systems through remote sensing and precision agriculture for more sustainable production – Towards Low Carbon Agriculture” (FAPESP 2017/50205-9) pela disponibilização dos dados; à Fundação de amparo à pesquisa do Estado de São Paulo - FAPESP (processo nº 2020/02223-0) pelo auxílio de bolsa concedido ao terceiro autor; e à Fazenda Campina (CV Nelore Mocho) pela disponibilização da área, suporte e assistência.

#### **REFERÊNCIAS**

- BOCCA, F. F.; RODRIGUES, L. H. A. The effect of tuning, feature engineering, and feature selection in data mining applied to rainfed sugarcane yield modelling. *Computers and Electronics in Agriculture*, v. 128, p. 67–76, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.compag.2016.08.015>>.
- CARNEIRO, F.M.; FURLANI, C.E.A.; ZERBATO, C.; MENEZES, P.C.; GIRIO, A. da S. Correlations among vegetation indices and peanut traits during different crop development stages. *Engenharia Agrícola*. v.39, p.33-40, 2019.
- GAVIOLI, A. et al. Identification of management zones in precision agriculture: An evaluation of alternative cluster analysis methods. *Biosystems Engineering*, v. 181, p. 86–102, 2019. Disponível em: <<https://doi.org/10.1016/j.biosystemseng.2019.02.019>>.
- MOLIN, J. P.; AMARAL, L. R.; COLAÇO, A. *Agricultura de Precisão*. São Paulo: Oficina de textos, 2015.
- ROBNIK-ŠIKONJA, M., KONONENKO, I. An adaptation of relief for attribute estimation in regression. In: *Proc. 14th Int. Conf. Machine Learning (ICML '97)*. Morgan Kaufmann, San Francisco, CA, USA, p. 296–304, 1997.
- PYLE, D. *Data Preparation for Data Mining*. San Francisco: Morgan Kaufmann Publishers, Inc, 1999.
- RUSS, G.; KRUSE, R. Feature Selection for Wheat Yield Prediction. In: *Research and Development in Intelligent Systems XXVI, Anais...2010*.
- SCHENATTO, K., et al. Normalization of data for delineating management zones. *Computers and Electronics in Agriculture*, v. 143, p. 238–248, 2017.
- SONG, Q.; SHEPPERD, M. Missing data imputation techniques. *International Journal of Business Intelligence and Data Mining*, v. 2, n. 3, p. 261–291, 2007.



VAN GROENIGEN, J.W.; SIDERIUS, W.; STEIN, A. Constrained optimisation of soil sampling for minimisation of the kriging variance. *Geoderma*, v.87, p.239–259, 1999.

# 7. Outros

# DISTRIBUIÇÃO LONGITUDINAL DE SEMENTES DE MILHO MENSURADA POR IMAGENS E ESTEIRA COM GRAXA

**Marcelo Chan Fu Wei<sup>1</sup>; Maurício Martello<sup>2</sup>; José Paulo Molin<sup>3</sup>**

<sup>1</sup>Eng° Agrônomo, Doutorando - Depto Engenharia de Biossistemas, ESALQ, USP, Piracicaba - SP. marcelochan@usp.br / (11) 9 5359-9011; <sup>2</sup>Eng° Ambiental, Doutorando - Depto Engenharia de Biossistemas, ESALQ, USP, Piracicaba - SP; <sup>3</sup>Eng° Agrícola, Professor - Depto Engenharia de Biossistemas, ESALQ, USP, Piracicaba - SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** A produtividade, especialmente em culturas de sementes graúdas, pode ser afetada pela desuniformidade de distribuição de sementes. É função das semeadoras de precisão distribuí-las com espaçamento uniforme. Entretanto, é necessário avaliar a qualidade de distribuição de sementes em função das variáveis de deslocamento da máquina e do espaçamento pré-estabelecido. Os métodos atuais consistem na mensuração manual em esteira com feltro ou graxa. Além desses métodos, existem os que se utilizam de sensores com destaque aos ópticos e fotoelétricos, que apresentam menor onerosidade para obter os dados, porém o seu uso ainda é limitado seja por falta de capacidade de detecção de sementes múltiplas (fotoelétricos) ou poucos estudos que demonstrem a viabilidade da aquisição dos dados pela imagem (ópticos), sendo este uma forma passível de automatização que pode reduzir custos com insumos para o seu teste. Diante disso, o objetivo do trabalho foi avaliar a uniformidade da distribuição longitudinal de uma semeadora pelo método da esteira com graxa e por imagem. O experimento foi conduzido com uma esteira com graxa, câmera digital, semeadora de precisão e sementes de milho. Foram avaliados quatro tratamentos com seis repetições, variando a densidade populacional e velocidade da semeadora. Os espaçamentos entre as sementes foram mensurados diretamente na esteira e a partir da análise dos quadros obtidos dos vídeos gravados durante os testes. Os dados de espaçamentos foram classificados de acordo com o intervalo de tolerância em relação ao seu referencial e classificados como aceitáveis, falhos e múltiplos. Os métodos foram comparados pelo teste de comparação múltipla de Tukey a um nível de 5% de significância. Os métodos de mensuração do espaçamento não apresentaram diferença estatística entre si. O trabalho indica o potencial da aplicação de imagens para obter a distância entre sementes de milho com o intuito de avaliar a qualidade da distribuição longitudinal de uma semeadora, sendo que a partir do seu uso pode-se reduzir a necessidade de insumos utilizados, com destaque para a graxa/feltro e sementes.

**PALAVRAS-CHAVE:** espaçamento; semeadora de precisão; qualidade de distribuição

## LONGITUDINAL DISTRIBUTION OF MAIZE SEEDS THROUGH IMAGES AND MAT WITH GREASE

**ABSTRACT:** Crop yield, especially in large seeds crop, can be affected by the uneven seed distribution. Precision seeder acts to distribute seeds evenly spaced. However, it is required to evaluate the distribution quality as function of tractor displacement and preset spacing. The current methods are based on manual measurements on mat with grease or felt. Besides these methods, there are sensor-based, especially optical and photoelectric ones, in which data acquisition is less onerous, but their use is still limited either due to lack of capacity to detect multiple seeds (photoelectric) or few studies that demonstrate the feasibility of acquiring data by image (optical) being this a method that can be automated reducing costs with inputs during tests. The objective of this work was to evaluate the longitudinal distribution uniformity of a seeder through image and mat with grease. The experiment was conducted with a mat with grease, digital camera, precision seeder and maize seeds. Four treatments were evaluated with six repetitions varying seed density and seedling speed. The spacings between seeds were measured on the mat and through images. After that, these data were classified according to the tolerance interval in relation to their reference as acceptable, flawed and multiple. A Tukey test with 5% of significance was applied to compared the methods. The measurement methods were statistically equal. This work presents the potential to apply image processing to obtain maize seed spacing to

evaluate the quality of a precision seeder distribution and from its use, the need for inputs can be reduced, especially grease/felt and seeds.

**KEYWORDS:** distribution quality; spacing; precision seeder

**INTRODUÇÃO:** A distribuição desuniforme de sementes pode reduzir a produtividade de grãos quando comparado a uma distribuição uniforme (WADE et al., 1988). Para melhorar a qualidade de distribuição de sementes, torna-se necessário o uso de semeadoras com mecanismo dosador de precisão (GOMES, 2018). Este mecanismo, disposto entre o reservatório e o tubo condutor de sementes, é responsável pela individualização das sementes de acordo com o espaçamento definido e as variáveis de deslocamento da máquina. A velocidade de operação da semeadora é uma das principais variáveis que afetam na qualidade da distribuição longitudinal das sementes (MIALHE, 2012). Dessa maneira, a avaliação da qualidade de distribuição de sementes pelas semeadoras em função da velocidade de deslocamento e densidade populacional desejada torna-se fundamental. Para isso, em teste laboratoriais, a prática comum é a medição de sementes em linha única a partir de uma esteira equipada com feltro ou cinto pegajoso, como nos estudos de Jasper et al. (2009). Esse teste é considerado preciso e acurado, entretanto possui alguns pontos limitantes, como onerosidade na determinação do espaçamento entre as sementes por se tratar de um método manual, limitação do número de dados devido a extensão da esteira e o alto risco de deslizamento ou não fixação das sementes no cinto (KARIMI et al., 2015). Pesquisas voltadas a desenvolver sistemas de avaliação laboratorial da uniformidade de espaçamento entre sementes com uso de sensores está se tornando comum (KARAYEL et al., 2006, KOSTIC et al., 2018). Como por exemplo, Lan et al. (1999) compararam o uso de sensores ópticos e a esteira pegajosa para avaliarem a uniformidade de distribuição de uma semeadora e obtiveram erros de 97 mm entre as medidas. Kostic et al. (2018) avaliaram a distribuição longitudinal de uma semeadura comparando os resultados obtidos por meio da análise de imagens e sensor fotoelétrico. Apesar dos resultados encontrados pelos autores serem satisfatórios, eles destacam pontos que limitam o uso dos sensores fotoelétricos, principalmente em relação à detecção de sementes consideradas de espaçamento múltiplo. Com isso, ressalta-se a importância de dar continuidade na exploração do uso de sensores ópticos para mensuração da qualidade de distribuição de semeadoras uma vez que a sua análise de espaçamento entre sementes pode se tornar automatizada, reduzindo gastos com cinta pegajosa, sementes e tempo de análise, entretanto ainda é necessário mais estudos que abordem o uso da imagem para estimar os espaçamentos entre a deposição das sementes. O objetivo foi avaliar a uniformidade da distribuição longitudinal de sementes em uma semeadora com a mensuração da distância entre sementes de milho obtida por imagens, tendo os espaçamentos obtidos em esteira com graxa como referencial comparativo.

**MATERIAIS E MÉTODOS:** O estudo foi desenvolvido no Departamento de Engenharia de Biosistemas da Escola Superior de Agricultura “Luiz de Queiroz” (ESALQ) da Universidade de São Paulo (USP). Como sistema de referência foi adotado uma esteira de borracha com 13 m de comprimento total, equipada com um motor elétrico de 3 CV e inversor de frequência para regulagem da velocidade (Figura 1a e 1b). O segundo sistema utilizado para avaliar a distribuição das sementes foi uma câmera digital modelo *Hero 3 Black*, fabricante *GoPro* (Califórnia, EUA), com resolução espectral na faixa do visível (350 ~ 700 nm – RGB) com um sensor CMOS (*Complementary Metal Oxide Semiconductor*) com capacidade de gravar vídeos a uma frequência de 240 FPS (*frames per second* – quadros por segundo) com resolução de 840 *pixels* de largura por 480 *pixels* de altura. Foi utilizada uma semeadora de precisão com disco perfurado horizontal de 22 furos, instalada a uma altura de 0,13 m entre a saída do distribuidor e a esteira. A semeadora contava com depósito individualizado preenchido com sementes de milho híbrido, cultivar 20A55PW padronizadas (tamanho e forma) e tratadas com fungicida. A semeadora foi adaptada com um motor elétrico de 3 CV e um inversor de frequência para o controle do sentido e velocidade com o intuito da realização dos testes em bancada.



FIGURA 1. Equipamento utilizado para avaliação da qualidade de distribuição de sementes de milho. (a) esteira de borracha equipada com motor elétrico e inversor; (b) dois inversores de frequência, esteira (imagem superior) e semeadora (imagem inferior). **Equipment used to assess the quality of maize seed distribution. (a) rubber mat equipped with electric motor and frequency inverter; (b) two frequency inverters, mat (upper image) and seeder (lower image).**

Foram determinados quatro tratamentos, variando a velocidade de distribuição das sementes (Tabela 1) com seis repetições cada, totalizando 24 coletas. A esteira permaneceu a uma velocidade constante de  $0,222 \text{ m s}^{-1}$ . Esta velocidade era quatro vezes menor que a da semeadora, permitindo assim aumentar a densidade de sementes na esteira, uma vez que o comprimento é limitado, e consequentemente um X referência (X Ref – espaçamento de referência entre sementes) de esteira proporcionalmente menor que a referência teórica.

TABELA 1. Tratamentos utilizados para avaliar a qualidade da distribuição da semeadora de precisão em função da densidade populacional de sementes de milho, velocidade teórica e frequência do inversor da semeadora. **Applied treatment to assess the distribution quality of the precision seeder as function of maize seed population density, theoretical velocity and seeder inverter frequency.**

Tratamentos	População (sementes $\text{ha}^{-1}$ )	X Ref Esteira (m)	X Ref Teórico (m)	Velocidade Teórica ( $\text{m s}^{-1}$ )	Inversor Semeadora (Hz)
A	50.000	0,1111	0,4444	0,889	1,000
B	70.000	0,0833	0,3332	1,067	1,400
C	85.000	0,0667	0,2668	1,333	1,800
D	100.000	0,0556	0,2224	1,600	2,200

X Ref = X referência – espaçamento de referência entre sementes.

Para atingir a velocidade necessária de trabalho foi determinada a quantidade de sementes distribuídas em 27 s, tempo necessário para a esteira percorrer os 6,0 m definido como distância efetiva. Foi inserida uma fina camada ( $\sim 0,003 \text{ m}$  de espessura) de graxa sobre a esteira com a função de reter as sementes no local exato da

queda. Para cada coleta, primeiramente, era acionada a esteira e logo após a semeadora, a partir da primeira semente fixada na esteira era iniciada a contagem até alcançar os 6,0 m lineares. Ao final, a semeadora era desligada e, posteriormente, a esteira. Para a determinação da distribuição longitudinal era medida a distância manualmente de cada semente com um esquadro e uma fita métrica disposta na lateral da esteira (Figura 2a). A determinação da distribuição longitudinal pelas imagens foi obtida a partir da fixação da câmara na lateral da semeadora a uma distância de 0,21 m da saída do distribuidor e 0,32 m do fundo instalado com um material emborrachado verde com a função de contrastar a semente no momento do processamento das imagens (Figura 2b).



FIGURA 2. Métodos utilizado para mensuração das distâncias entre as sementes de milho. (a) aferição pelo uso de um esquadro metálico e fita métrica e (b) disposição do sensor óptico para posterior mensuração a partir de imagens. **Applied methods to measure the distances between maize seeds. (a) measurement obtained from a metallic square and measuring tape and (b) optical sensor placement to further obtain distance measurements from images.**

Para cada coleta de dados com a câmera foi gravado um vídeo com taxa de quadros a 240 FPS. Os vídeos foram separados de acordo com o tratamento e repetição, os processamentos para extração de dados foram executados de forma manual, utilizando o aplicativo nativo do Windows 10 (Fotos). O aplicativo permitiu avaliar quadro a quadro do vídeo com a informação de tempo, extraindo-se os valores de tempo de cada semente que passava pela saída do distribuidor, conforme exemplificado na Figura 3.




FIGURA 3. Exemplo da obtenção das distâncias entre as sementes de milho a partir de imagens. (a) quadro com a semente 1 (S1) na linha de referência (LR) e tempo 1 (T1) da semente S1; (b) quadro com a semente 2 (S2) na linha de referência com S1 na esteira, tempo 2 (T2) da semente S2 e (c) quadro com a semente 3 (S3) na linha de referência com S2 e S1 na esteira, tempo 3 (T3) da semente S3. **Example of distance measurement between maize seeds from images. (a) frame with seed 1 (S1) on the reference line (LR) on time 1 (T1); (b) frame with seed 2 (S2) on the LR with S1 on the mat and time 2 (T2) and (c) frame with seed 3 (S3) on the LR with S1 and S2 on the mat and time 3 (T3).**

Para os dados obtidos manualmente, a distância entre sementes foi calculada subtraindo a posição da semente em questão com a anterior. Já com os dados obtidos pelas imagens, a distância foi obtida aplicando a equação



da distância em função da velocidade e tempo. Os valores de distância/espaçamento entre sementes ( $x_i$ ) foram classificadas de acordo com ABNT (1996), Tabela 2.

TABELA 2. Classificação de espaçamento entre sementes de acordo com o intervalo de tolerância para variação do  $X_i$  (ABNT, 1996). **Seed spacing classification according to the variation tolerance of  $X_i$  (ABNT, 1996).**

Tipos de Espaçamento – Classes	Intervalo de tolerância para variação de $X_i$
Múltiplo	$x_i < 0,5 X \text{ Ref}$
Aceitáveis	$0,5 X \text{ Ref} < x_i < 1,5 X \text{ Ref}$
Falhas	$x_i > 1,5 X \text{ Ref}$

$x_i$  = espaçamento entre sementes;  $X \text{ Ref}$  = espaçamento de referência entre sementes

Com os dados brutos foram realizadas duas filtragens. A primeira foi realizada com o intuito de remover apenas valores que não correspondiam com a classificação do  $X \text{ Ref}$ . Sendo assim, foram eliminados os valores considerados “falsos positivos” e a segunda filtragem foi efetuada para eliminar dados que sofreram influência com relação à trajetória da semente no momento da queda, porém não influenciando na classificação do  $X \text{ Ref}$ . Para isso foi calculada a diferença entre espaçamentos dos dois métodos e extraídos os valores duas vezes maiores ou menores que o desvio padrão da média dessa diferença. A partir disso, com o intuito de avaliar os dois métodos foram realizadas duas análises: a) um teste de comparação de médias de Tukey a um nível de 5% de significância entre os dois métodos e b) uma análise de regressão linear entre o espaçamento calculado pelo vídeo *versus* o espaçamento mensurado na esteira.

**RESULTADOS E DISCUSSÃO:** Adotando o critério de espaçamentos aceitáveis, múltiplos e falhos, temos graficamente a distribuição das classificações para cada tratamento, representadas na Figura 4 com os tratamentos A, B, C e D (Figura 4a-d). Observa-se que os resultados comparativos entre ambos os métodos não são 100% correlacionados, ou seja, existem valores considerados como falso-positivos. Estes valores são aqueles em que a classificação é diferente entre as metodologias utilizadas para mensuração do espaçamento entre sementes, tornando desta maneira, necessária a realização da primeira filtragem.

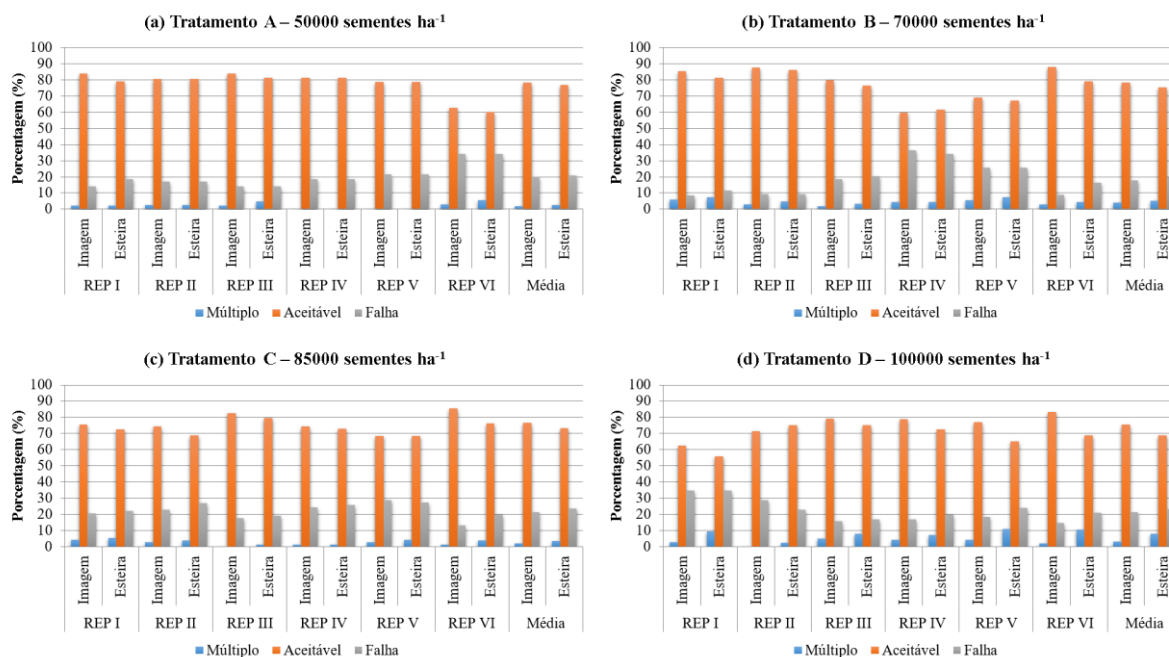


FIGURA 4. Classificação da distribuição longitudinal do espaçamento das sementes de milho de acordo com o intervalo de tolerância (ABNT, 1996) para a mensuração pela esteira e imagem. (a) tratamento A (50.000



sementes ha<sup>-1</sup>); (b) tratamento B (70.000 sementes ha<sup>-1</sup>); (c) tratamento C (85.000 sementes ha<sup>-1</sup>) e (d) tratamento D (100.000 sementes ha<sup>-1</sup>). **Seed spacing classification according to the tolerance interval (ABNT, 1996) to the mat and image measurements. (a) treatment A (50,000 seeds ha<sup>-1</sup>); (b) treatment B (70,000 seeds ha<sup>-1</sup>); (c) treatment C (85,000 seeds ha<sup>-1</sup>) and (d) treatment D (100,000 seeds ha<sup>-1</sup>).**

Com os dados devidamente filtrados, realizou-se a análise de variância dos fatores, neste caso, indicando que existe uma diferença significativa ao nível de 5% de probabilidade apenas para o fator tratamento. As metodologias avaliadas para mensuração do espaçamento entre as sementes apresentaram p-valores inferiores que 0,05, indicando que são semelhantes, corroborando com resultados encontrados por outros trabalhos (KARAYEL et al., 2006; KOSTIC et al., 2018). A partir disto, prosseguiu-se com um teste de comparação de médias para os tratamentos com o intuito de verificar como foi a diferenciação dos tratamentos entre si. A Tabela 3 indica que todos os tratamentos foram estatisticamente diferentes entre si ao nível de 5 % de probabilidade, porém quando nos referimos aos métodos, o resultado indica que os métodos são estatisticamente iguais.

TABELA 3. Teste de Tukey para comparação entre tratamentos e métodos de estimativa de espaçamento entre sementes de milho. **Tukey test comparison among treatment and method to estimate spacing distribution between maize seeds.**

Método	Espaçamento médio por tratamento (cm)			
	A	B	C	D
Câmera	14,49* Aa	9,80* Ba	8,04* Ca	6,53* Da
Esteira	14,45* Aa	9,79* Ba	8,04* Ca	6,52* Da

\* nível de 5% de probabilidade Valores médios seguidos de letras maiúsculas são comparados na horizontal (entre tratamentos) e letras minúsculas, na vertical (entre métodos). Letras maiúsculas iguais na linha e letras minúsculas iguais na coluna não apresentam diferença estatística entre si a um nível de 5% de probabilidade.

Adicionalmente, a Figura 5 ilustra a correlação entre os valores obtidos pelos dois métodos para todos os tratamentos. É oportuno destacar que o método da esteira com graxa é tido como exato, mas incorpora incertezas como pequenos deslocamentos pela inércia das sementes na queda e leitura visual de distâncias. O gráfico indica que o modelo proposto neste trabalho para mensuração do espaçamento com as filtragens utilizadas, é adequado se comparado com os dados da esteira e corrobora com os dados obtidos por trabalhos que também utilizaram imagens para mensurar o espaçamento entre sementes (KARAYEL et al, 2006; KOSTIC et al, 2018).




FIGURA 5. Regressão linear entre os espaçamentos de sementes de milho mensurados na esteira e os espaçamentos obtidos pelo processamento de imagens. **Linear regression among maize seed spacing measured on the mat and estimated by image processing.**

Com o desenvolvimento do trabalho foi possível observar na prática alguns pontos negativos em trabalhar com a metodologia da esteira com graxa, como: a dificuldade em realizar grandes amostras devido ao comprimento limitado da esteira; o tempo necessário para realizar uma coleta; onerosidade da amostragem considerando que após a mensuração das distâncias era preciso retirar manualmente semente por semente; necessidade de descarte do material vegetal após mensuração, uma vez que elas entraram em contato com a graxa; descarte do material vegetal em local adequado, dentre outros. Assim, torna-se oportuno desenvolver métodos alternativos que permitam estimar com maior exatidão e menor onerosidade a distribuição longitudinal de sementes. O sistema utilizando câmera digital apresentou alto potencial, porém são necessários mais estudos visando desenvolver um algoritmo a partir de visão computacional para realizar a contagem, estimativa e classificação dos espaçamentos de forma automática. A partir deste algoritmo, é necessário avaliar diferentes sistemas dosadores de semeadora e desenvolver um protocolo para avaliação da regularidade de distribuição de sementes por parte dos usuários.

**CONCLUSÃO:** A avaliação da regularidade da distribuição longitudinal de sementes de milho utilizando câmera digital apresentou alta correlação com o método de esteira com graxa, viabilizando a sua utilização como alternativa ao método comparado.

## REFERÊNCIAS

- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (ABNT). Projeto de norma 04:015.06-004/1995. *Semeadora de precisão: ensaio laboratório/método de ensaio*. São Paulo: ABNT, 1996. 21p.
- GOMES, A. R. A. *Avaliação de sensores ópticos para monitoramento da operação de semeadura em milho e soja*. 2018. 82 f. Tese (Doutorado em Agronomia). Faculdade de Ciências Agrônomicas, Universidade Estadual de São Paulo, Brasil.
- JASPER, R.; JUSTINO, A.; MORGADO, C.B.; DYCK, R.; & GARCIA, L.C. Comparação de bancadas simuladoras do processo de semeadura em milho. *Engenharia Agrícola*, v. 29, n. 4, p. 623-629, 2009.
- KARIMI, H.; NAVID, H.; MAHMOUDI, A. Online laboratory evaluation of seeding-machine application by an acoustic technique. *Spanish Journal of Agricultural Research*, v. 13, n. 1, 2015.

KARAYEL, D.; WIESEHOFF, M.; OZMERZI, A., MULLER J. Laboratory measurement of seed drill seed spacing and velocity of fall of seeds using high-speed camera system. **Computers and Electronics in Agriculture**, v. 50, p. 89-96, 2006.

KOSTIC, A.M.; RAKIC, B.D.; RADOMIROVICA, D.; SAVINA, L.; DEDOVICA N.; CRNOJEVIC V.; LJUBICIC N. Corn seeding process fault cause analysis based on a theoretical and experimental approach. **Computers and Electronics in Agriculture**, v 151, p.207-218, 2018.

LAN, Y.; KOCHER, M.F.; SMITH, A. Opto-electronic sensor system for laboratory measurement of planter seed spacing with small seeds. **Journal of Agricultural Engineering Research**, v. 72, p. 119–127, 1999.

MIALHE, L.G. **Máquinas agrícolas para plantio**. Campinas: Editora Millennium, 2012. 648 p.

WADE, L.J.; NORRIS, C.P.; WALSH, P.A. Effects of suboptimal plant density and non-uniformity in plant spacing on grain yield of rain-grown sunflower. **Australian Journal of Experimental Agriculture**, v. 28, p. 617–622, 1988.

# DESENVOLVIMENTO DE UM SISTEMA EMBARCADO DE BAIXO CUSTO PARA MONITORAMENTO DE DESEMPENHO ENERGÉTICO DE TRATOR

Thais Souza Santos<sup>1,2</sup>; Mariana Dias Meneses<sup>5</sup>; Eduardo José dos Santos<sup>2</sup>; Agnaldo Santana Santos<sup>2</sup>; Wellington Gonzaga do Vale<sup>3,4</sup>

<sup>1</sup>Estudante de Engenharia Agrícola, Graduando - Depto. Engenharia Agrícola, UFS - SE. th\_souza98@hotmail.com / ; <sup>2</sup>Estudante de Engenharia Agrícola, Graduando - Depto. Engenharia Agrícola, UFS - SE; <sup>3</sup>Engenheiro Agrícola, Professor Doutor - Depto. Engenharia Agrícola, UFS - SE; <sup>4</sup>Engenheiro Agrícola, Professor Doutor - Depto. Engenharia Agrícola, UFS - SE; <sup>5</sup>Engenheira Agrícola, Pós graduanda em ciência do solo - Depto. de Engenharia e Ciências Exatas, Unesp (FCAV) - SP

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Buscando atender um mercado consumidor cada vez mais exigente, o produtor rural usa de novas tecnologias para sanar essa demanda aumentando a produtividade, a qualidade do produto final e reduzindo os custos de produção. Para isso, usa de máquinas e implementos agrícolas em diversas das atividades que realiza no campo, devido a isso, o monitoramento de tais máquinas e das atividades se faz necessário para garantir um trabalho preciso e rápido. A utilização de sensores e sistemas embarcados que auxiliem nesse monitoramento é indispensável para garantir uma análise precisa das atividades, entretanto algumas dessas ferramentas ainda tem um alto custo de obtenção, dificultando a aquisição por pequenos e médios produtores. Sendo assim, o presente projeto teve como objetivo desenvolver, testar e validar um sistema alternativo que mensurasse o consumo de diesel pelo trator. O projeto foi desenvolvido usando Arduino e um sensor de fluxo, os testes foram realizados em campo e os dados foram analisados e os resultados obtidos mostraram que o aparato foi capaz de mensurar o consumo de combustível pelo trator de modo rápido e preciso. Além disso, os materiais utilizados possibilitaram a construção de um aparato com um valor abaixo do comum.

**PALAVRAS-CHAVE:** Arduino; Automação; Sensores

## DEVELOPMENT OF A LOW COST EMBEDDED SYSTEM FOR TRACTOR ENERGY PERFORMANCE MONITORING

**ABSTRACT:** Seeking to meet an increasingly demanding consumer market, rural producers use new technologies to meet this demand by increasing productivity, the quality of the final product and reducing production costs. For this, it uses agricultural machinery and implements in several of the activities it performs in the field, due to this, the monitoring of such machines and activities is necessary to guarantee a precise and fast work. The use of sensors and embedded systems that help in this monitoring is essential to guarantee an accurate analysis of the activities, however some of these tools still have a high cost, making it difficult to acquire by small and medium farmers. Therefore, the present project aimed to develop, test and validate an alternative system to measure diesel consumption by the tractor. The project was developed using Arduino and a flow sensor, the tests were carried out in the field, the data were analyzed and the results showed that the apparatus was able to measure fuel consumption by the tractor quickly and accurately. In addition, the materials used allowed the construction of an apparatus with a value below the common.

**KEYWORDS:** Arduino; Automation; Sensors

**INTRODUÇÃO:** A gradativa evolução do setor agrícola no país traz consigo uma exigência por técnicas mais apuradas que deverão suprir as exigências do mercado consumidor com precisão e eficiência. Para suprir essas exigências a utilização de tecnologias nos trabalhos do campo se tornou um meio para garantir uma produção eficaz e eficiente. Responsável por atender essas demandas, a Agricultura 4.0 insere novas técnicas no uso de máquinas, implementos, sensores e tecnologias capaz de aprimorar a produção, reduzindo custos e impactos ambientais (MASSRUHÁ; LEITE, 2017; SANTOS; ESPERIDIÃO; AMARANTE, 2019).

A utilização das ferramentas da Agricultura 4.0 permite preservar, controlar e regular as atividades agrícolas e o maquinário responsável por desenvolvê-las. Um dos meios de garantir esse controle nas atividades com utilização de máquinas é através da racionalização das operações, ato este que consiste na caracterização, modo de execução e seleção dos equipamentos que estarão envolvidos nas atividades (VALE, 2011).

A seleção e calibração das máquinas e implementos que serão utilizados nas atividades do campo trás resultados positivos quanto à produtividade e qualidade do produto final. Valendo ressaltar também que o correto gerenciamento desses maquinários é essencial visto o valor investido nos mesmos, podendo variar entre 20% a 40% do total gasto na produção, a depender da cultura implantada e da necessidade dos usos de implementos que a mesma requer (FRANTZ, 2011).

Através da implementação de sensores, é possível obter dados das atividades com maquinário e posteriormente processá-los para que a administração dos trabalhos seja feita. Para Júnior (2017), a utilização de sensores embarcados possibilita a captura de dados sem a interferência humana, proporcionando um monitoramento em tempo real de maneira rápida e precisa. Além disso, existe a possibilidade, por meio de códigos de programação, de implementar equações matemáticas para a filtragem e refinamento dos dados, todo esse processo de modo automático e podendo ser acompanhado em tempo real através de monitores e *displays* e viabilizando a correção de erros ainda durante a atividade no campo.

Ciente que as operações realizadas com tratores são imprescindíveis para agricultura e que as despesas com operadores e combustível são as mais elevadas entre as operações realizadas (VALE, 2011), e que o uso de sistemas embarcados ainda não é comum devido ao seu custo de aquisição, se faz necessário o investimento em estudos para criar métodos alternativos para garantir o gerenciamento das atividades de maneira precisa e com um valor de mercado acessível.

Desse modo, o presente projeto teve como objetivo desenvolver, testar e validar um sistema para analisar o desempenho energético do trator, testes foram realizados para a obtenção de dados de consumo de diesel com o aparato criado.

**MATERIAIS E MÉTODOS:** O projeto foi desenvolvido em três etapas, foram elas: construção do aparato, testes e validação em campo. O aparato foi desenvolvido no Laboratório de Máquinas e Motores (LAMOT), do departamento de Engenharia Agrícola da Universidade Federal de Sergipe (UFS). Para a construção do mesmo foram utilizados os dispositivos da Tabela 1, os itens foram adquiridos no mercado local e na internet. TABELA 1. Dispositivos utilizados para construção do aparelho.

Dispositivos	Descrição
Arduino ATmega 2560	Microcontrolador
Placa <i>Ethernet-MicroSD Shield</i>	Placa de prototipagem
Fluxômetro	Sensor OVAL Corporation LFS45
Cabos <i>jumpers</i>	Cabos de conexão
Cartão de memória	Cartão MicroSD de 36Gb

A placa Ethernet foi conectada ao Arduino e nela foram soldados os demais elementos acima citados. Para que fosse possível realizar as medições de consumo e gravar os dados em um arquivo .txt foi criado um script de programação na plataforma Arduinon IDE (Integrated Development Environment). O código tinha como finalidade contabilizar o volume de combustível por unidade de tempo, para isso foi necessário utilizar da Equação 1 para converter os pulsos gerados pelo fluxômetro, em volume por unidade de tempo.  $Ch = (Np * 3,6) / t$  (1) em que: Ch - consumo horário (L/h); Np - número de pulsos do fluxômetro; t - tempo de percurso nos 50 metros (s); e 3,6 - unidade de conversão para L/h. O consumo volumétrico foi obtido com a média das leituras a cada 3 segundos durante o percurso de 50 metros. Todos os valores foram salvos automaticamente no cartão de memória do dispositivo. Após construir o dispositivo foram realizados os testes em campo. Esses foram feitos na fazenda Gandu (Figura1) localizada no município de Arauá, em Sergipe (11°17'8''S

37°37'51''O) no dia 18 de abril de 2020. O solo foi classificado como Latossolo pedozólico vermelho amarelo de textura média/argilosa sem cobertura vegetal.




FIGURA 1.

Localização da área dos testes. Nos testes foi utilizado um trator John Deere modelo 6110 J 4x4, com suas características descritas na Tabela 2. TABELA 2. Especificações do trator John Deere.

Trator John Deere modelo 6110 J 4x4	
Potência do motor na rotação nominal	110 cv a 2.300 rpm
Faixa de rotação com potência constante	1.500-2.300 rpm
Torque máximo	429N.m a 1.400 rpm
Pneus	14.9 R1 e 23.1-30 R1
Massa (com lastro)	6.000 Kg

Durante os testes foram utilizadas as marchas A1, B1, B3 e C2 e suas respectivas velocidades teóricas de deslocamento (Tabela 3), com a tração dianteira auxiliar (TDA) do trator não acionada. TABELA 3. Marchas utilizadas e suas respectivas velocidades teóricas.

Marchas	Velocidade teórica (km/h)
A1	2,5
B1	5,3
B3	7,5
C2	10,1

Para realização do experimento, o aparato foi alimentado pela bateria do trator e o fluxômetro foi instalado depois do primeiro filtro de combustível. No retorno dos bicos e da bomba injetora, entre o medidor e a bomba de sucção, foi conectado um T, de forma a criar um sistema fechado e impedir que o diesel não passe mais de uma vez pelo sensor (Figura 2). Antes do fluxômetro foi acoplada uma mangueira com 2 m de comprimento




FIGURA 2.

para garantir que o fluxo do diesel fosse laminar.

Localização do sensor de consumo e sentido do fluxo de diesel. Os testes foram conduzidos seguindo um delineamento inteiramente casualizado sendo as 4 marchas (A1, B1, B3 e C1) os tratamentos com três repetições para cada uma.

**RESULTADOS E DISCUSSÃO:** Os itens adquiridos para a construção do aparato custaram um total de R\$2.440,44 (Tabela 4).

Material	Un	Qt.	Preço unitário (R\$)	Preço total (R\$)
Pacote de fio <i>jumpers</i>	Un	2	8,00	16,00
MicroSD card	Un	1	30,00	30,00
Arduino com cabo USB	Un	1	65,00	65,00
ProtoShield	Un	1	15,00	15,00
Ethernet-MicroSD Shield	Un	1	55,00	55,00
Sensor OVAL M-III LSF41	Un	1	2.200,00	2.200
Mangueira trançada 3/8	m	2	3,12	6,24
Emenda latão escamada	Un	3	5,12	15,36
Tee latão	Un	1	12,45	12,45
Espigão latão macho	Un	2	10,00	20,00
Abraçadeira	Un	7	0,77	5,39
Total				R\$2.440,44

O custo de construção do aparato foi cerca de 50% mais baixo que os sistemas tradicionais, o fato de usar um Tee no sistema possibilitou o uso de apenas um sensor de fluxo, em aparatos tradicionais existe a utilização de dois sensores, fator este que aumenta o valor de aquisição do sistema em mais de R\$2.000,00. A primeira etapa do projeto teve seu objetivo concluído com a criação de um código de programação que foi capaz de fazer as leituras de pulso através do sensor e posteriormente converte-las em consumo médio e armazena-las no cartão de memória. A instalação e o funcionamento do fluxômetro foram bem sucedidos, possibilitando o funcionamento correto do trator sem a contagem do diesel mais de uma vez (Figura 3).





FIGURA 3. Instalação do fluxômetro no trator. Essa

instalação e o código possibilitaram obter o consumo de diesel durante a realização do percurso para cada um dos tratamentos e a média de cada um deles (Tabela 4). TABELA 4. Média do consumo de diesel para cada tratamento.

Tratamento	Média (L/h)	CV(%)
A1	20,63	0,79
B1	21,88	1,32
B3	22,34	1,79
C1	22,77	1,45

**CONCLUSÃO:** Os resultados obtidos mostram que o dispositivo foi eficiente e pode ser utilizado em campo. O aparato mostrou-se confiável, obtendo os dados com de maneira rápida e precisa, além disso, a utilização de apenas um sensor de fluxo reduz do valor de construção do aparato em mais de R\$2.000,00, possibilitando a utilização do aparato para o pequeno e médio produtor.

#### REFERÊNCIAS

FRANTZ, U. G. **Análise de desempenho em tração de rodado simples e duplo em um trator agrícola.** 2011

JÚNIOR, D. C. **DESENVOLVIMENTO E VALIDAÇÃO DE UM SISTEMA EMBARCADO PARA MONITORAMENTO DE OPERAÇÕES AGRÍCOLAS COM TRATORES.** p. 87, 2017.

MASSRUHÁ, S. M. F. S.; LEITE, M. A. DE A. **Agro 4.0 - rumo à agricultura digital. - Portal Embrapa.** Disponível em: <<https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1073150/agro-40---rumo-a-agricultura-digital>>. Acesso em: 6 out. 2021.

SANTOS, T. C. DOS; ESPERIDIÃO, T. L.; AMARANTE, M. DOS S. **AGRICULTURA 4.0. Revista Pesquisa e Ação,** v. 5, n. 4, p. 122–131, 5 dez. 2019.

VALE, W. G. **Desempenho operacional e energético de um trator agrícola durante as operações de roçagem, aração e sementeira.** 2011. 2017 f. Tese (Doutorado em Produção Vegetal) - Centro de Ciências e Tecnologias Agropecuárias, Universidade Estadual do Norte Fluminense Darcy Ribeiro, Campos dos Goytacazes, 2011.

# ANÁLISE ESPACIAL DA ENTALPIA EM GALPÃO PARA CRIAÇÃO DE COELHOS BRANCOS NOVA ZELÂNDIA

Patricia Ferreira Ponciano Ferraz<sup>1</sup>; Rafaella Resende Andrade<sup>2</sup>; Gabriel Araujo e Silva Ferraz<sup>4</sup>; Luana Mendes Dos Santos<sup>3</sup>; Maria Alice Junqueira Gouvêa Silva<sup>5</sup>

<sup>1</sup>Zootecnista, Professora - Departamento de Engenharia Agrícola, Universidade Federal de Lavras (UFLA). patricia.ponciano@ufla.br / (35) 9 9935-8485; <sup>2</sup>Eng. Agrícola, Pesquisadora - DAGRI-Department of Agricultural, Environmental, Food and Forestry, Universidade de Florença - Itália; <sup>3</sup>Eng. Agrícola, Doutora - Autônoma, Autônoma; <sup>4</sup>Eng. Agrícola, Professor - Departamento de Engenharia Agrícola, Universidade Federal de Lavra -UFLA; <sup>5</sup>Zootecnista, Doutoranda - Departamento de Zootecnia, Universidade Federal de Lavra -UFLA

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** Os sistemas de alojamento e as práticas de manejo exercem forte influência no bem-estar e na produção de coelhos, tornando a escolha do ambiente de criação extremamente importante. O objetivo deste estudo foi avaliar a Entalpia (H) de um galpão para a criação de coelhos brancos Nova Zelândia (NZW) por meio de técnicas geoestatísticas. Além disso, buscou-se avaliar sua relação com a frequência respiratória (FR) e a temperatura da superfície da orelha (TSO). Foram coletados dados em 48 pontos no interior do galpão, durante sete dias do final do verão. As medições de temperatura do ar, umidade relativa e velocidade do vento foram feitas às 12h. Posteriormente, calculou-se a H e realizou-se uma análise dos dados utilizando as ferramentas da geoestatística e a confecção de mapas de isocores por meio da interpolação por krigagem. Com base nos resultados da geoestatística foi possível caracterizar a magnitude e a estrutura da variabilidade dessa variável no interior do galpão. Observou-se, por meio dos mapas de isocores, a heterogeneidade da distribuição espacial da H em diversas regiões do galpão. Assim, foram identificados pontos críticos da H dentro do galpão e em locais onde estavam alojados animais com alta FR e TSO, fornecendo informações sobre como melhorar o ambiente de produção.

**PALAVRAS-CHAVE:** bem-estar animal; cunicultura; geoestatística

## SPATIAL ANALYSIS OF ENTHALPY IN A FACILITY FOR BREEDING NEW ZEALAND WHITE RABBITS

**ABSTRACT:** Housing systems and management practices have a strong influence on rabbit welfare and production, making the choice of rearing environment extremely important. The aim of this study was to evaluate the Enthalpy (H) of a rabbit house for New Zealand white rabbits (NZW) using geostatistical techniques. In addition, we sought to assess its relationship with respiratory rate (RR) and ear surface temperature (EST). Data were collected at 48 points inside the rabbit house, during seven days at the end of summer. Air temperature, relative humidity and wind speed measurements were taken at 12:00h. Subsequently, the enthalpy was calculated and an analysis of the data was carried out using the tools of geostatistics and the creation of isocore maps through kriging interpolation. Based on the results of geostatistics, it was possible to characterize the magnitude and structure of the variability of this variable inside the rabbit house. It was observed, through isocore maps, the heterogeneity of the spatial distribution of H in different regions of the shed. Thus, critical points of H were identified inside the shed and in places where animals with high RF and EST were housed, providing information on how to improve the production environment.

**KEYWORDS:** animal welfare; rabbit breeding; geostatistics

### INTRODUÇÃO:

O Brasil possui grande potencial agrícola devido à sua extensa área de terra, o que favorece o estabelecimento de diversos tipos de sistemas de produção, principalmente os sistemas pecuários, incluindo a cunicultura

(Ferraz et al., 2019a). Tal atividade apresenta crescimento no país, pois possibilita a produção de carne de alto valor nutricional e pele de excelente qualidade com baixo investimento (Silva et al., 2021).

Contudo, para elevar os índices de produção tem sido constante a busca por técnicas mais modernas e viáveis que proporcionem maior bem-estar e conforto aos animais, aliadas a sustentabilidade. Nesse sentido, deve-se atenção ao tipo de sistema de criação adotado, pois o microclima para a produção de coelhos tem forte influência no desempenho produtivo e reprodutivo, na saúde e bem-estar dos animais, e o desconforto térmico pode prejudicar significativamente o seu desenvolvimento (Silva et al., 2021).

Para um bom desempenho produtivo, os coelhos devem ser submetidos a uma temperatura ideal ( $t_{bs}$ ), entre 15 e 25 °C e umidade relativa (UR) entre 60 e 70% (Ferreira et al., 2012). Com base nessas informações, a entalpia (H) pode ser calculada. A H é uma propriedade termodinâmica que pode ser utilizada para avaliar o ambiente térmico de animais (Rodrigues et al., 2010). Adicionalmente, uma série de processos fisiológicos, incluindo frequência respiratória (FR) e temperatura da superfície da orelha (TSO), estão relacionados às respostas adaptativas usadas pelos animais (Berghof et al., 2019).

Assim, têm-se buscado ferramentas computacionais que possam auxiliar nos processos de avaliação e tomada de decisão para apoiar melhores ambientes de produção (Andrade et al., 2021; Ferraz et al., 2019b). O mapeamento geoestatístico pode ser importante para a análise das condições ambientais e fisiológicas dos animais em sistemas de produção. Portanto, o objetivo deste estudo foi desenvolver uma distribuição espacial de mapas de entalpia (H) via interpolação de krigagem, bem como avaliar sua relação com as respostas fisiológicas (FR e TSO) de coelhos brancos mantidos em galpão com cloaca próxima à distribuição espacial da H.

## MATERIAIS E MÉTODOS:

O experimento foi conduzido em um galpão de criação de coelhos do setor de Cunicultura do Departamento de Zootecnia da Universidade Federal de Lavras (UFLA), Minas Gerais, Brasil. Foram utilizados 52 coelhos brancos da Nova Zelândia (NZW) (28 machos e 24 fêmeas), com 58 dias de idade. Os coelhos foram alojados aleatoriamente em 26 gaiolas coletivas de arame galvanizado (2 animais por gaiola). Durante o período experimental, os animais tiveram livre acesso a ração balanceada e água potável.

O galpão estava orientado no sentido leste-oeste, possuía 6,20 m de largura, 9,60 m de comprimento e 3,0 m de pé direito, com 1,0 m de beiral do telhado. A cobertura foi construída com telhas de barro com inclinação de 30°. O piso era de concreto, com duas valas coletoras de cimento de 1,50 × 6,00 m e 0,80 m de profundidade no centro do alojamento. As paredes laterais foram feitas de alvenaria com 0,80 m de altura. O galpão possuía um cumeeira para auxiliar na renovação do ar e ventilação do ambiente interno. A abertura da cumeeira sobre a telha foi medida como 5% da largura total do galpão (0,30 m) e tinha uma inclinação de 20% da largura total do galpão (1,70 m).

### *Medições de Resposta Ambiental e Fisiológica*

Em maio de 2016, os dados de temperatura de bulbo seco ( $t_{bs}$ , °C), umidade relativa do ar (UR, %) e velocidade do ar (WS,  $m s^{-1}$ ) foram medidos a 1,0 m de altura dentro do galpão. Adicionalmente foram coletados os dados de frequência respiratória (FR, batimento  $min^{-1}$ ) e temperatura da superfície da orelha (TSO, °C) dos coelhos. Todas as variáveis foram coletados durante sete dias, sempre às 12h.

As variáveis  $t_{bs}$  e UR foram avaliadas por meio de termo higrômetro digital (INSTRUTEMP®, mod. ITWH-1280, precisão de  $\pm 0,1$  °C e 1,0%). A WS foi medida com anemômetro digital (Kerstrel 4000, precisão de  $\pm 3,0\%$ ). No interior do galpão, os sensores foram posicionados formando uma grade de 1,0 x 1,0 m, totalizando 48 pontos de dados coletados.

Posteriormente a coleta dos dados de  $t_{bs}$  e UR, o H foi calculado através da Eq. 1 desenvolvida por Albright (1990).

$$H = 1,006t_{bs} + W(2501 + 1,805t_{bs}) \quad \text{Eq. (20)}$$

Onde: H - entalpia, em kJ kg<sup>-1</sup> ar seco; T<sub>bs</sub> - temperatura de bulbo seco, em °C; e, W - razão de mistura, em kg kg<sup>-1</sup> ar seco; calculada pela Eq. 2 .

$$W = \frac{(0,622e_a)}{P_{atm} - e_a} \quad \text{Eq. (21)}$$

Onde: e<sub>a</sub> - pressão de vapor d'água, em kPa; e, P<sub>atm</sub> - pressão atmosférica, em kPa.

A FR foi avaliada contando os movimentos de flanco dos coelhos com um cronômetro digital (± 0,01 s). Os movimentos respiratórios dos animais foram monitorados por 15 s e então multiplicados por quatro para obter as respirações por minuto (Batimentos min<sup>-1</sup>) (Zeferino et al., 2011). A TSO (°C) foi medida em três pontos diferentes na orelha do animal (base, meio e ponta), e a média dos valores foi calculada. Um termômetro infravermelho (Raytek Raynger ST, Raytek Corporation, precisão de ± 0,1 °C) foi usado com o controle de emissividade ajustado para 0,95 (Ferraz et al., 2019c).

### Validação dos Modelos

Após os resultados obtidos a partir do cálculo da H, a variabilidade espacial foi analisada usando ajustes de semivariogramas e interpolação por krigagem ordinária. Este método foi utilizado para prever os níveis das variáveis em locais não amostrados no interior do galpão de criação de coelhos. Para a estimativa do semivariograma, foi utilizado o estimador de Matheron (1962), conforme Eq. 3, para quantificar a dependência espacial das variáveis dentro do galpão:

$$\hat{\gamma}(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(X_1) - Z(X_i + h)]^2 \quad \text{Eq. (22)}$$

Onde: N(h) é o número de pares de observação Z(X<sub>i</sub>) e Z(X<sub>i</sub> + h) separados por uma distância h.

Do ajuste de um modelo matemático  $\hat{y}(h)$ , foram obtidos os coeficientes do modelo teórico para o semivariograma, chamado efeito pepita (C<sub>0</sub>), contribuição (C<sub>1</sub>), patamar (C<sub>0</sub> + C<sub>1</sub>) e alcance (a). O Grau de Dependência Espacial (GDE) foi utilizado para analisar a dependência espacial e calculado a partir da razão entre o efeito pepita (C<sub>0</sub>) e o patamar (C<sub>0</sub> + C<sub>1</sub>). Para analisar o GDE dos atributos em estudo, utilizou-se da classificação de Cambardella et al. (1994), em que são considerados uma forte dependência em semivariogramas com GDE ≤ 0,25; dependência moderada em semivariogramas com 0,25 < GDE ≤ 0,75 e dependência fraca em semivariogramas com GDE > 0,75. A validação foi usado para determinar o erro médio, desvio padrão do erro médio, erro médio reduzido e desvio padrão de o erro médio reduzido. Dessa forma, pode-se verificar se os ajustes nos semivariogramas atendiam aos requisitos e se eram satisfatórios.

O semivariograma foi ajustado pelo Método de Máxima Verossimilhança Restrita (REML), conforme sugerido por Marchant e Lark (2007). O modelo matemático utilizado para realizar o ajuste do semivariograma foi o esférico, muito utilizado em estudos geoestatísticos, pois são referenciados em geoestatística como modelos transitivos (modelos com patamar C<sub>0</sub> + C<sub>1</sub>). A seleção do modelo esférico justifica-se por ser o que melhor se adapta aos ajustes em estudos nas variáveis ambientais em instalações para animais (Ribeiro et al., 2016), foi feito de acordo com metodologia proposta por Vieira et al. (2010)

Conhecido o semivariograma das variáveis e ocorrendo dependência espacial, foram confeccionados os mapas da distribuição espacial dos níveis de H através da técnica de krigagem ordinária dos dados. A análise geoestatística e a plotagem de mapas de isolinhas foram realizadas em R (R Development Core Team) usando o pacote geoR. O software QGIS versão 2.14.15 (Quantum GIS Development Team) foi usado para criar os layouts dos mapas.

Os dados de FR e TSO foram cruzados e sobrepostos aos mapas de dados ambientais finais do galpão de coelhos.

**RESULTADOS E DISCUSSÃO:** As técnicas da geoestatísticas foram utilizadas para melhor avaliar quantitativa e qualitativamente a entalpia (H), o que forneceu informações importantes sobre a sua

variabilidade e influência no ambiente estudado. Os modelos e parâmetros dos semivariogramas experimentais ajustados para a H no galpão de coelhos são apresentados na Tabela 1.

TABELA 1. Método REML, modelo esférico e parâmetros estimados de semivariogramas experimentais para a entalpia no interior da coelheira NRV e WRV durante os sete dias analisados, às 12h. **REML method, spherical model and estimated parameters of experimental semivariograms for enthalpy inside a rabbit shed during the seven days analyzed, at 12:00.**

Dia	C <sub>0</sub>	C <sub>1</sub>	C <sub>0</sub> + C <sub>1</sub>	a	a'	GDE	EM	DP <sub>EM</sub>	ER	S <sub>ER</sub>
1	0,33	3	3,14	0,43	1,30	0,11	0,006	1,09	0,00	1,00
2	4,95	8,86	13,82	1,08	3,22	0,36	0,005	2,53	0,00	1,00
3	5,37	6,57	11,94	1,23	3,69	0,45	-0,012	2,52	0,00	1,00
4	1,90	2,10	4,00	1,01	3,01	0,47	-0,021	1,58	-0,01	1,02
5	0,00	40,78	40,78	54,26	162,56	0,00	0,004	0,64	0,00	0,79
6	0,00	23,73	23,73	11,35	34,00	0,00	-0,042	1,01	-0,01	0,73
7	0,00	84,42	84,42	23,74	71,11	0,00	0,004	1,63	0,00	0,91

C<sub>0</sub> – efeito pepita; C<sub>1</sub> – contribuição; C<sub>0</sub> + C<sub>1</sub> – patamar; a – alcance; a' – alcance prático e GDE – grau de dependência espacial; EM - erro médio; DP<sub>EM</sub> - Desvio padrão do erro médio; ER - Erro reduzido; S<sub>ER</sub> - Desvio padrão do erro reduzido. REML - Método de Máxima Verossimilhança Restrita.

Pela Tabela 1 verificou-se que houve dependência espacial durante todos os dias analisados. Assim, a distribuição espacial da H não foi homogênea, o que pode afetar as respostas fisiológicas dos coelhos NZW e potencialmente expô-los a condições térmicas desconfortáveis dentro do galpão analisado. A contribuição da variável H ao longo do período experimental apresentou valores de C<sub>0</sub> abaixo de 0,25, para os dias 1, 5, 6 e 7, representando forte dependência espacial.

O presente estudo analisou a magnitude e variabilidade espacial da H em uma coelheira NZW utilizando valores estimados via krigagem para a produção de mapas isocores com espacialização da H, visualizando a variabilidade espacial desta variável ao longo do período experimental dentro do galpão (Figura 1) . Ao observar os mapas de krigagem, fica evidente que houve uma variação espacial de H entre os dias avaliados, indicando que os animais criados neste ambiente estariam submetidos a diferentes condições ambientais dentro de um mesmo galpão.

A H pode ser considerado como conforto com valores entre 31,1 e 62,6 kJ kg<sup>-1</sup> ar seco que foram calculados por meio da equação (Eq. 1; Albright, 1990) em função dos parâmetros de t<sub>bs</sub> e UR propostos por Ferreira et al. (2012) e Jaruche et al. (2012), respectivamente. Nos 7 dias analisados, às 12h, a H do galpão sempre esteve fora da faixa considerada ideal, possivelmente devido à alta t<sub>bs</sub> que ocorreu nesses dias e aos baixos valores de UR encontrados durante o período experimental, que influenciaram a valores de H do interior. Além disso, os menores valores de H foram observados, apenas no dia 5, porém também acima do ideal. Em relação ao conforto térmico e bem-estar dos coelhos, deve-se ressaltar que esses animais são mais sensíveis ao calor do que ao frio, portanto, mudanças bruscas nas condições térmicas são mais prejudiciais do que uma mudança gradual de temperatura fora da zona de conforto (Petrescu & Petrescu-Mag, 2018).

De acordo com Baracho et al. (2013), os animais atingem sua produtividade ótima quando são criados em ambiente termoneutro, ou seja, quando a energia da alimentação não é desviada para compensar os desvios térmicos da faixa termoneutra para eliminar ou manter sua temperatura corporal. Dessa forma, quando coelhos são submetidos a condições térmicas diferentes do seu conforto térmico, podem prejudicar o desempenho produtivo do animal.

Além disso, os dados de FR e TSO foram cruzados e sobrepostos nos mapas finais dos dados de H (Figura 1). Com base nos parâmetros fisiológicos FR e TSO, ambos apresentaram relação direta com a distribuição espacial do ITU. Isso se deve à sua grande variabilidade espacial ao longo do galpão, demonstrando que o aumento do ITU levou a uma aceleração dos movimentos respiratórios e à elevação da temperatura da superfície da orelha do coelho. Quando os coelhos estão fora da zona de homeotermia, o aumento da FR é um dos mecanismos necessários para estimular a perda de calor por evaporação (Ferraz et al., 2019c). Portanto, Zeferino et al. (2011) relataram que, para coelhos sob homeotermia, sua FR deveria variar entre 32 e 60 batimentos  $\text{min}^{-1}$ . De acordo com a literatura, a orelha de coelho desempenha um papel importante na regulação da temperatura por ser o leito vascular cutâneo primário (Nalivaiko & Blessing, 1999). Lublin et al. (1995) mencionaram em sua pesquisa que em condições termoneutras a TSO pode variar de 26,4 a 26,9 °C. Às 12h, para todos os dias avaliados, grande parte do plantel apresentava FR variando entre 80 a 180 respirações. $\text{min}^{-1}$  e TSO variando entre 26 e 29°C, demonstrando que, nestes momentos, os coelhos NZW possivelmente estavam sentindo desconforto térmico.

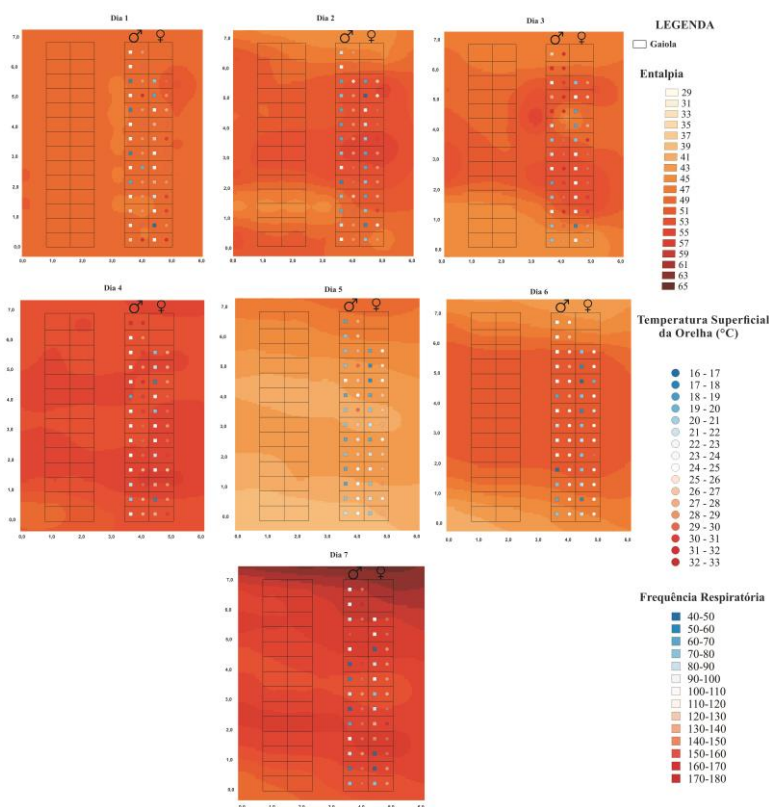


FIGURA 1. Distribuição espacial da entalpia (H), frequência respiratória (FR, respirações. $\text{min}^{-1}$ ) e temperatura da superfície da orelha (EST, °C) de coelhos brancos da Nova Zelândia (NZW) às 12h, durante sete dias dentro de um galpão de coelhos. **Spatial distribution of the enthalpy (H), respiratory frequency (RF, breaths. $\text{min}^{-1}$ ), and ear surface temperature (°C) of New Zealand white (NZW) rabbits at 12:00 p.m., over seven days inside a rabbit house.**

**CONCLUSÃO:** Observou-se que houve heterogeneidade da distribuição espacial dos parâmetros ao longo dos dias avaliados, para o horário avaliado de 12h. A relação entre H, FR e TSO foi evidente. Os mapas mostraram um elevado H para os sete dias avaliados, o que levou a uma aceleração dos movimentos respiratórios e um aumento na temperatura da superfície da orelha dos coelhos. Esta foi uma tentativa de dissipar o excesso de calor adquirida do meio ambiente. Assim, foram identificados pontos críticos da H dentro do galpão e em locais onde estavam alojados animais com alta FR e TSO, fornecendo informações sobre como melhorar o ambiente de produção.

**AGRADECIMENTOS:**

À Universidade Federal de Lavras (UFLA/Brasil), onde o experimento foi realizado, à Universidade de Firenze (UNIFI/Itália) pelo apoio a esta pesquisa.

## REFERÊNCIAS

ALBRIGHT, L.D. Environment control for animals and plants. 1.ed. St Joseph: **American Society of Agricultural Engineers**, p.453, 1990.

ANDRADE, R.R.; TINÔCO, I.F.F.; DAMASCENO, F.A.; FREITAS, L.C.S.R.; FERREIRA, C.F.S.; BARBARI, M.; BAPTISTA, F.J.F.; REZENDE COELHO, D. J. Spatial distribution of bed variables, animal welfare indicators, and milk production in a closed compost-bedded pack barn with a negative tunnel ventilation system. **Journal of Thermal Biology**, v.105, p.103111, 2021.

BARACHO, M.S.; DE CASSIANO, J.A.; DE NÄÄS, I.A.; TONON, G.S.; GARCIA, R.G.; ROYER, A.F.B.; DE MOURA, D.J.; DE SANTANA, M.R. Ambiente interno em galpões de frango de corte com cama nova e reutilizada. **Rev. Agrar.**, v.6, p.473–478, 2013

BERGHOF, T.V.L; POPPE, M.; MULDER, H.A. Opportunities to Improve Resilience in Animal Breeding Programs. **Frontiers in Genetics**, v.9 , p.1-7, 2019.

CAMBARDELLA, C. A.; MOORMAN, T. B.; PARKIN, T. B.; KARLEN, D. L.; NOVAK, J. M.; TURCO, R. F.; KONOPKA, A. E. Field-scale variability of soil properties in central Iowa soils. **Soil Science Society of America Journal**, v.58, p.1501-1511, 1994.

FERRAZ, P.F.P.; FERRAZ, G.A.S.; BARBARI, M.; SILVA, M.A.J.G., DAMASCENO, F.A.; CECCHIN, D.; CASTRO, J.O. Behavioural and physiological responses of rabbits. **Agron. Research**, v.17, p.704-710, 2019a.

FERRAZ, P.F.; FERRAZ, G. A.; DAMASCENO, F.A.; MOURA, R.S. D., SILVA, M. A., & RODRIGUES, R. D. L. Spatial variability of enthalpy in rabbit house with and without ridge vent. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.23, p.126-132, 2019b.

FERRAZ, P.F.P.; HERNÁNDEZ-JULIO, Y.F.; E SILVA FERRAZ, G.A.; DE MOURA, R.S.; ROSSI, G.; SARAZ, J.A.O.; BARBARI, M. Decision trees for predicting the physiological responses of rabbits. **Animals**, v.9, p.994, 2019c.

FERREIRA, W. M.; MACHADO, L. C.; JARUCHE, Y. DE G.; CARVALHO, G. G. DE; OLIVEIRA, C. E. A. DE; SOUZA, J. A. S.; CARÍSSIMO, A. P. G. (eds.). **Manual prático de cunicultura. BambuÍ: Associação Brasileira de Cunicultura**, p.75, 2012.

JARUCHE, Y.G.; FARIA FILHO, D.E.F.; DIAS, A.N.; FERNANDES, D.P.; RIBEIRO, H.O.C.; SIQUEIRA, A.A.; SIMA, P.S.; ORNELAS, O.T.C.; CRUZ, L.J.; CAIXETA, V.; BARBOSA, P. M. Efeito da densidade de alojamento sobre a homeostase térmica em coelhas em crescimento mantidas em diferentes temperaturas. **Rev. Brasileira de Cunicultura**, v.1, p.1-42, 2012.

LUBLIN, A.; WOLFENSON, D.; BERMAN, A. Diferenças sexuais na distribuição do fluxo sanguíneo de coelhos normotérmicos e estressados pelo calor. **Sou. J. Physiol. Regul. Integr. Comp. Physiol.**, v.268, p.66–71, 1995.

MATHERON, G. Treaty of applied geostatistics. Vol. I: **Mémoires du Bureau de Recherches Géologiques et Minières**, Editions Technip, Paris, n. 14, 1962.

MARCHANT, B. P.; LARK, R. M. Robust estimation of the variogram by residual maximum likelihood. **Geoderma**, v.140, p.62-72, 2007.

NALIVAICO, E.; BLESSING, W.W. Synchronous changes in ear and tail blood flow following salient and noxious stimuli in rabbits. **Brain Res.**, v.847, p.343–346, 1999.



PETRESCU, D.C.; PETRESCU-MAG, R.M. Consumer behaviour related to rabbit meat as functional food. **World Rabbit Sci.**, v.26, p.321–333, 2018.

RIBEIRO, P. A. P.; YANAGI JUNIOR, T.; OLIVEIRA, D. D. DE; FERRAZ, G. A. E S.; LOURENÇONI, D. Análise geoestatística das iluminâncias em aviários para poedeiras equipados com lâmpadas fluorescentes compactas e de led. **Engenharia Agrícola**, v.36, p.962-971, 2016.

RODRIGUES, V.C.; SILVA, I.J.O.; VIEIRA, F.M.C.; NASCIMENTO, S.T.A correct enthalpy relationship as thermal comfort index for livestock. **International Journal Biometeorology**, v.55, p. 455-459, 2010.

SILVA, M.A.J.G.; FERRAZ, P.F.P.; SANTOS, L.M.D.; FERRAZ, G.A.E.S.; ROSSI, G.; BARBARI, M. Effect of the Spatial Distribution of the Temperature and Humidity Index in a New Zealand White Rabbit House on Respiratory Frequency and Ear Surface Temperature. **Animals**, v.11, p.1657, 2021.

ZEFERINO, C.P.; MOURA, A.S.A.M.T.; FERNANDES, S.; KANAYAMA, J.S.; SCAPINELLO, C.; SARTORI, J.R. Genetic group × ambient temperature interaction effects on physiological responses and growth performance of rabbits. **Livestock Science**, v.140, p.177–183, 2011.

# PROTÓTIPO DE SISTEMA PARA COLETA DE IMAGENS DE POMARES PARA PREVISÃO DE COLHEITA

Darlan Alaor Selzlein<sup>1</sup>; Carlos Moyses Abrahão Auzi Ribeiro<sup>2</sup>; Luciano Gebler<sup>3</sup>; Pedro Luiz de Paula Filho<sup>4</sup>

<sup>1</sup>Cientista da Computação, Graduando - Universidade Tecnológica Federal do Paraná, Medianeira, PR. darlan.s@alunos.utfpr.edu.br / (45) 9 9817-8069; <sup>2</sup>Cientista da Computação, Graduando - Universidade Tecnológica Federal do Paraná, Medianeira, PR; <sup>3</sup>Eng° Agrônomo, Pesquisador - Embrapa Uva e Vinho, Vacaria, RS; <sup>4</sup>Doutor em Ciência da Computação, Professor - Depto. Acadêmico de Computação, DACOM, Universidade Tecnológica Federal do Paraná, Medianeira, PR

Apresentado no  
**Congresso Brasileiro de Agricultura de Precisão- ConBAP 2022**  
Campinas, SP, 09 a 11 de agosto de 2022

**RESUMO:** A coleta de dados é a base para o ciclo da agricultura de precisão. Na fruticultura, a metodologia de coleta de dados ainda está fortemente embasada na ação empírica de monitoramento visual por parte de técnicos e produtores. O desenvolvimento de sistemas de coleta de dados automatizado tem sido visto como um apoio importante ao processo de AP em fruticultura, logo a coleta de imagens através do sensoriamento proximal em solo, devido aos sistemas de cultivo cobertos, tem apresentado uma evolução constante. Algumas dificuldades foram detectadas que precisam ser ajustadas, mas as técnicas de ajuste de imagem disponíveis atualmente permitem dar solução a este problema. O uso do *stitching* na coleta de imagens em pomares pode ajudar na adoção de métodos de predição e estimação, necessários para avaliar a efetividade das ações corretivas dos efeitos da variabilidade espacial e temporal em pomares de frutas.

**PALAVRAS-CHAVE:** *Stitching*; Fruticultura de Precisão; Maçã

## SYSTEM PROTOTYPE FOR COLLECTION OF ORCHARD IMAGE FOR HARVEST FORECAST

**ABSTRACT:** Data collection is the foundation for the precision agriculture cycle. In fruit growing, data collection methodology is still strongly based on the empirical action of visual monitoring by technicians and producers. Development of automated data collection systems has been seen as an important support to the PA process in fruit growing, so the collection of images through proximal sensing in soil due to covered cropping systems, has presented a constant evolution. Some difficulties were detected that need to be fixed, but the image adjustment techniques currently available allow solving this problem. The use of stitching in the collection of images in orchards can help in the adoption of prediction and estimation methods, necessary to evaluate the effectiveness of corrective actions for the effects of spatial and temporal variability in fruit orchards.

**KEYWORDS:** Stitching; Precision Fruit Growing; Apple

**INTRODUÇÃO:** Diante da crescente necessidade de alimentos, o desenvolvimento tecnológico vem transformando a agricultura com o objetivo de possibilitar o aumento do potencial produtivo do sistema agrícola (SANTOS & NASCIMENTO, 2009).

A captura de imagens é útil na agricultura de precisão e costuma ficar a cargo de veículos aéreos, tripulados ou não, permitindo trabalhos como os de Feng *et al.* (2020), que utiliza imagens aéreas para analisar a qualidade da emergência de plantas de algodão. Após a coleta, as imagens podem ser utilizadas na estimação de produção ou previsão de cenários, segundo os efeitos da variabilidade espacial e temporal, bastando seu tratamento por modelos apropriados (SANTOS & GEBLER, 2021). Porém, na cultura da macieira, e em outras frutíferas, é comum o uso permanente de telas de cobertura para proteção contra granizo, aves, chuvas, etc, inviabilizando a visão aérea. Por conta disso, a opção de coleta de imagens a partir de veículos de solo, tripulados ou não, passa a ser viável ou mesmo necessária.

Além disso, áreas agrícolas costumam ser grandes, sendo difíceis de serem fotografadas em uma única imagem com detalhamento necessário para trabalhos que demandam dessa precisão. Dessa forma, a área de Processamento de Imagens (PDI) pode auxiliar com tratamentos e manipulações de mosaicos de imagens de alta resolução obtidas nas lavouras que facilitem a extração de informações na escala centimétrica ou milimétrica.

Um exemplo de técnica útil é o uso do *stitching*, que consiste na colagem de fotos que tenham regiões em comum através da sobreposição e alinhamento dessas regiões, formando uma imagem panorâmica resultante da união das imagens originais (WANG & YANG, 2020).

O uso de técnicas de *stitching* pode ser visto em trabalhos como o de Tarallo *et al.* (2014), no qual imagens aéreas foram coladas para facilitar o diagnóstico de queimadas e controle de pragas de diversas culturas.

Sendo assim, buscou-se a opção de criar um sistema que coleta as imagens de qualidade de pomares de maçãs, para seu posterior uso na previsão de colheitas com base em veículos de solo (tripulados ou não), uma vez que o trânsito de maquinário agrícola na fruticultura é intenso ao longo de toda a safra, permitindo a entrada de câmeras sob a tela de proteção sem interferir na planilha de custos da atividade agrícola.

A partir das imagens coletadas, foram aplicadas técnicas de *stitching* para produzir imagens panorâmicas do pomar para possibilitar a realização da previsão da colheita das maçãs, dando continuidade ao trabalho realizado por Anzolin *et al.* (2021), aplicando em pomares reais as técnicas testadas em ambiente controlado.

**MATERIAIS E MÉTODOS:** Esta pesquisa foi desenvolvida em parceria com a Embrapa Uva e Vinho (Vacaria/RS), fazendo uso de seus campos experimentais de maçãs para testes de protótipo.

De acordo com Anzolin *et al.* (2021), os pomares de maçãs são organizados em fileiras de árvores, separados por uma distância, por entre as quais um trator faz o manejo da cultura, variando de 1,8 a 3,4 metros, e a altura das árvores podendo alcançar 4 metros. Logo, a distância entre o centro de um trator até o início da árvore varia de 0,9 a 1,7 metros, o que não permite que uma única câmera simples capture a árvore como um todo, devido a sua abertura focal. Diante disso, são necessárias mais de uma câmera dispostas em alturas diferentes, cada uma responsável por fotografar um segmento diferente da árvore. Além disso, para aumentar a distância entre as câmeras e a fileira a ser fotografada, foi estabelecido que as câmeras responsáveis por fotografar as árvores à direita do corredor deveriam estar mais próximas das árvores à esquerda dele e vice-versa, montadas de forma a criar um ângulo de coleta de imagens à frente do trator, impedindo a coleta de imagens da estrutura.




FIGURA 1. Estrutura montada em trator da Embrapa Uva e Vinho, Vacaria - RS.

Para a realização do experimento deste artigo foram utilizadas três câmeras fixadas em uma estrutura embarcada em um trator. A razão para isso é possibilitar que as fotos sejam obtidas durante atividades já

comuns no manejo da cultura, como durante a aplicação de agroquímicos. Esta abordagem pode ser observada na Figura 1.

A estrutura em questão possui uma altura de 2,5 metros, com o objetivo de permitir que as câmeras pudessem ser posicionadas e testadas em diferentes alturas e distâncias entre si, e foi fixada na frente do trator, utilizando o contrapeso dele como suporte. O esqueleto principal da estrutura é composto por duas barras de alumínio de perfil “U” perfuradas, fixadas entre si e no contrapeso do trator por quatro segmentos de tábua de pinus. Para melhorar a estabilidade da estrutura enquanto o trator se movimenta, foi feito um suporte de madeira ligando o topo da estrutura à cabine do trator (Figuras 1a e 1b).

Por fim, para facilitar a fixação das câmeras, foram elaborados dois suportes de madeira paralelos às barras de alumínio e verticalmente inclinadas em 45° para evitar que as câmeras fotografassem a própria estrutura, o que fez com que elas ficassem apontadas diagonalmente para as fileiras do pomar. A distância vertical utilizada entre as câmeras foi de 0,5 metros, sendo uma distância que garantiu que houvesse uma área de sobreposição considerável entre a foto de cada uma das câmeras, possibilitando a realização do *stitching* entre elas (Figura 1c).

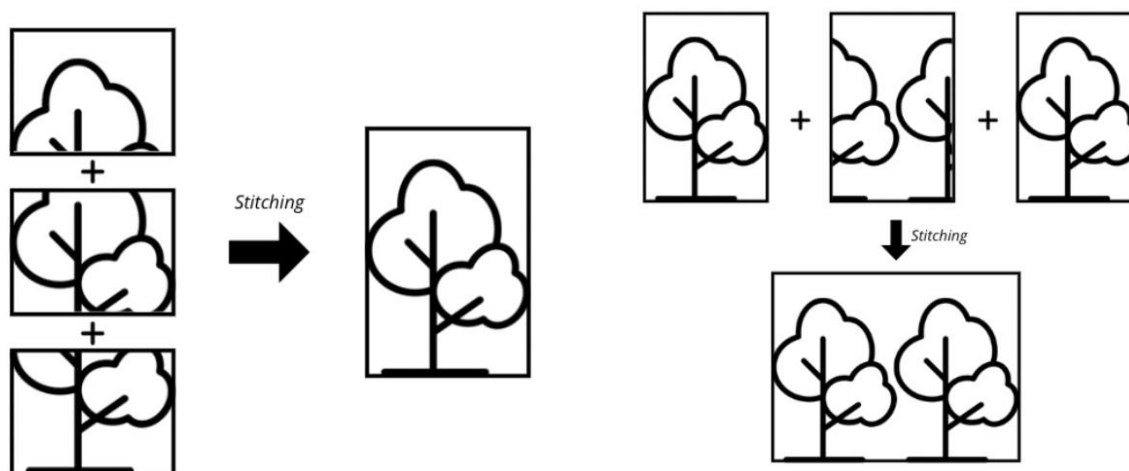
Embora o experimento realizado tenha utilizado apenas um lado da estrutura, ela foi construída de maneira a suportar câmeras de ambos os lados, permitindo fotografar as duas laterais dos corredores dos pomares ao mesmo tempo.

Além das câmeras, a estrutura dá suporte a um microcomputador Raspberry Pi, fixado na região central da estrutura e responsável por controlar todas as câmeras, e um carregador portátil, responsável por alimentar tanto o microcomputador quanto as câmeras.

Para coletar as fotos, um algoritmo conectou todas as câmeras e coletou fotos simultâneas em intervalo de tempo pré-determinado. O tempo entre fotos foi de meio segundo para garantir que houvesse a sobreposição entre as fotos tiradas horizontalmente.

Além disso, para simular um ambiente real durante a coleta de fotos, o trator se movimentou por entre as fileiras de macieiras com o giro de motor à 1700 RPM, alcançando uma velocidade normal de serviço (entre 3,5 a 5 km/h).

Para esse trabalho específico, o processo de *stitching* foi separado em duas etapas: o *stitching* vertical, realizando a colagem das 3 fotos obtidas pelas câmeras em cada intervalo de tempo; e o *stitching* horizontal, fazendo a colagem das imagens obtidas no *stitching* vertical. Após a união de todas as imagens de uma fileira, é possível uma única imagem panorâmica dela. Ambas etapas estão ilustradas na Figura 2.



a) *Stitching* vertical

a) *Stitching* horizontal

FIGURA 2. *Stitching* vertical (a) e *stitching* horizontal (b).

A finalidade de criar uma imagem desse tipo é permitir, futuramente, a contagem de frutos ou eventualmente, flores, gerando uma previsão de colheita, garantindo um resultado confiável, evitando que uma mesma fruta que apareça em diferentes fotos seja contada várias vezes.

**RESULTADOS E DISCUSSÃO:** Uma das preocupações antes da montagem era a respeito da estabilidade do equipamento, pois a vibração do trator em serviço poderia impedir a obtenção de imagens de qualidade, o que não se tornou um problema, pois a estrutura ficou bastante estável e uma das principais razões para isso, foi o suporte de madeira fixado no topo da estrutura até a cabine do trator.

A coleta das imagens foi realizada com sucesso, como pode ser visto na Figura 3a, porém há obstáculos a serem levados em conta que foram detectados durante a coleta de imagens no campo: reflexo do sol (Figura 3b) e borramento das imagens (Figura 3c).



a) Imagem adequada



b) Problema reflexo



c) Imagem borrada

FIGURA 3. Exemplos de imagens capturadas.

No processamento das imagens, foi possível realizar o *stitching* vertical e horizontal. Para isso, no entanto, foram usadas as imagens de apenas duas câmeras, pois elas foram suficientes para fotografar as árvores inteiras com boa taxa de sobreposição entre elas devido à altura das árvores ser de apenas aproximadamente 2,5 metros.

Para o *stitching* vertical, foram selecionadas fotos de dois tempos seguidos: tempo  $i$  e tempo  $i+1$ . O *stitching* para o tempo  $i$  (Figura 4c) se deu pela junção das fotos das câmeras 1 e 2 no tempo  $i$  (Figuras 4a e 4b). O *stitching* no tempo  $i+1$  (Figura 4f) ocorreu da mesma maneira para as fotos do tempo  $i+1$ . Por fim, para o *stitching* horizontal (Figura 4g), foi feita a união dos dois *stitchings* verticais.



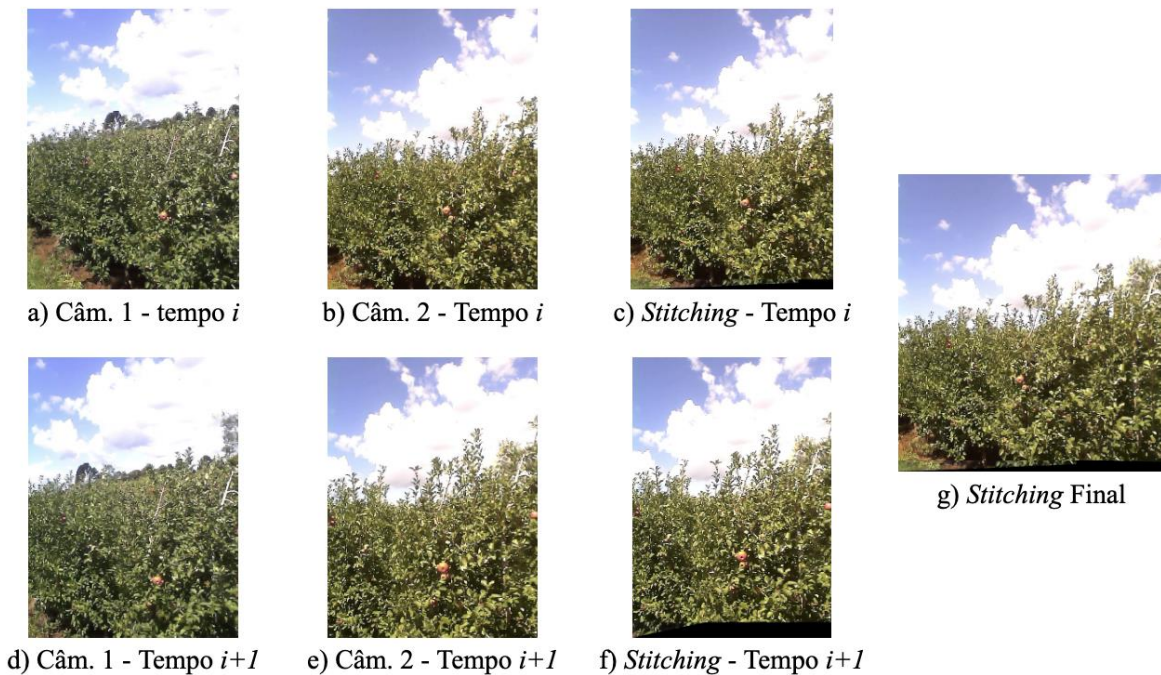


FIGURA 4. As imagens (a, b) e (d, e) foram processadas no stitching vertical com os respectivos resultados em (c) e (f), enquanto a imagem (g) e o resultado do processo do stitching horizontal.

Durante os procedimentos e testes ocorreram alguns problemas, devido à qualidade das imagens, como demonstrado nas Figuras 3b e 3c, não permitindo uma única imagem panorâmica de toda uma fileira árvores, entretanto, apesar dos problemas, foram coletadas mais de 4000 imagens aptas para o estudo e processamento. Isso demonstra a necessidade de maiores testes de campo e possivelmente variar os horários de coletas a fim de verificar os possíveis efeitos deletérios para as imagens durante todo o dia. Além disso, espera-se que sob a tela antigranizo, os efeitos referentes a ação direta do sol não venha a ser problema, diferente de novas questões como sombreamento excessivo ou escurecimento, condições que devem ser testadas e avaliadas.

**CONCLUSÃO:** Dados as atividades realizadas e os resultados obtidos, é possível perceber a aplicabilidade da ideia para a obtenção desse tipo de dado. Apesar dos desafios encontrados, as imagens coletadas pela estrutura puderam ser utilizadas na realização do *stitching*, restando agora, para trabalhos futuros, ajustar parâmetros para minimizar problemas de captura e realizar a contagem das maçãs para a previsão da produtividade através de técnicas de Inteligência Artificial.

Além disso, outros estudos e melhorias podem ser feitos a partir desta pesquisa, como a utilização da bateria do trator para alimentar o sistema no lugar do carregador portátil e o uso de seis câmeras simultâneas.

#### REFERÊNCIAS

SANTOS, Thiago. T.; GEBLER, Luciano. A methodology for detection and localization of fruits in apples orchards from aerial images. In: CONGRESSO BRASILEIRO DE AGROINFORMÁTICA, 13., p. 1-9, Anais [...]. Bagé: Unipampa, 2021. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/228160/1/PL-Methodology-detection-localization-SBIAgro-2021.pdf>

ANZOLIN, Tassiane Barbara Perico. Desenvolvimento de mosaico de imagens para automatização de processos na fruticultura de precisão. In: 18º Congresso Latino-americano de Software Livre e Tecnologias Abertas. Foz do Iguaçu: [s.n.], 2021

SANTOS, Aline; NASCIMENTO, Fábio. Transformações ocorridas ao longo da evolução da atividade agrícola: algumas considerações. ENCICLOPÉDIA BIOSFERA, v. 5, n. 08, 2009.

TARALLO, A. de S. et al. Uso de mosaico de imagens aéreas como ferramenta de auxílio ao diagnóstico de diversas culturas. Embrapa Instrumentação-Capítulo em livro científico (ALICE), 2014.

WANG, Zhaobin; YANG, Zekun. Review on image-stitching techniques. *Multimedia Systems*, Springer, v. 26, p. 413–430, 8 2020. ISSN 0942-4962. Disponível em: <http://link.springer.com/10.1007/s00530-020-00651-y>.

FENG, Aijing; ZHOU, Jianfeng; VORIES, Earl; SUDDUTH, Kenneth A. Evaluation of cotton emergence using uav-based narrow-band spectral imagery with customized image alignment and stitching algorithms. *Remote Sensing*, MDPI AG, v. 12, p. 1764, 5 2020. ISSN 2072-4292. Disponível em: <https://www.mdpi.com/2072-4292/12/11/1764>.



PROMOÇÃO



PATROCÍNIO DIAMANTE



Knowledge grows

PATROCÍNIO OURO



PATROCÍNIO PRATA



APOIO

