

BOLETIM DE

DIVULGAÇÃO TÉCNICA



INSTITUCIONAL

Boletim de Divulgação Técnica
Ano 01 | Nº 01 | Agosto de 2026

Diretoria da AsBraAP

Gestão 2024-2026

PRESIDENTE

Marcio Albuquerque

VICE-PRESIDENTE

Rodrigo Trevisan

2º VICE-PRESIDENTE

Christian Bredemeier

DIRETOR CIENTÍFICO

Lucas Amaral

VICE-DIRETOR CIENTÍFICO

Luis Basso

DIRETOR DE RELACIONAMENTO EMPRESARIAL

Jéssica Costalonga

DIRETOR DE RELACIONAMENTO GOVERNAMENTAL

Pedro Palatnik

DIRETOR DE RELACIONAMENTO ACADÊMICO

Rodrigo Zandonadi

GERENTE EXECUTIVA

Flávia Romanelli

NOTA DE RESPONSABILIDADE

Os conteúdos, informações, opiniões e recomendações apresentados nos textos publicados neste Boletim de Divulgação Técnica são de responsabilidade exclusiva de seus respectivos autores e não representam, necessariamente, o posicionamento institucional da Associação Brasileira de Agricultura de Precisão e Digital (AsBraAP). A AsBraAP não se responsabiliza por eventuais erros, omissões ou consequências decorrentes da utilização das informações apresentadas.

SUMÁRIO

Boletim de Divulgação Técnica
Ano 01 | Nº 01 | Agosto de 2026

> OPINIÃO DO USUÁRIO

ZONAS DE MANEJO PARA AMOSTRAGEM DE SOLO E PRESCRIÇÃO DE FERTILIZANTES: CONCEITOS, POTENCIAIS E LIMITAÇÕES

Amaral, L.R. p.04

> OPINIÃO DO USUÁRIO

VITIVINICULTURA DE PRECISÃO.

Basso, L.H. p.07

> NOTA TÉCNICA

EXPERIMENTAÇÃO ON-FARM: CONCEITOS E APLICAÇÕES NA TOMADA DE DECISÃO AGRONÔMICA.

Colaço, A.F. p.09

> NOTA TÉCNICA

MAPAS DE PRODUTIVIDADE DE SOJA EM OPERAÇÕES CONDUZIDAS COM MÚLTIPLAS COLHEDORAS: ESTRATÉGIA DE OPERAÇÃO E PROCESSAMENTO DE DADOS.

Zandonadi, R.S. p.14

> NOTA TÉCNICA

ÍNDICE DE VEGETAÇÃO POR DIFERENÇA NORMALIZADA (NDVI) E SUAS APLICAÇÕES NA AGRICULTURA.

Vian, A.L.; Bredemeier, C. p.21

EQUIPE EDITORIAL

Editor-chefe: Prof. Dr. Lucas R. Amaral

Editores associados: Prof. Dr. André Vian • Prof. Dr. André Colaço

Diagramação: Laura D. Bejarano • Mateus K. Trevisani



ZONAS DE MANEJO PARA AMOSTRAGEM DE SOLO E PRESCRIÇÃO DE FERTILIZANTES: CONCEITOS, POTENCIAIS E LIMITAÇÕES

LUCAS RIOS DO AMARAL¹

¹ Professor Associado, Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas - lucas.amaral@feagri.unicamp.br

A agricultura de precisão, amplamente adotada no país, foi sustentada desde o início de sua adoção, em meados dos anos 2000, pela amostragem de solo em grade, seguida pela interpolação dos dados do laboratório de análise para a criação dos mapas de fertilidade e de recomendação de fertilizantes em doses variadas. No entanto, há consenso de que essa investigação demanda alto investimento para ser realizada de forma eficaz e que, portanto, muitas vezes o número de amostras, também chamado de densidade amostral, fica aquém do ideal para a correta caracterização da variabilidade química dos solos agrícolas. Assim, nos últimos anos tem crescido o interesse pelo processo de amostragem de solo baseado em zonas de manejo. Aqui já fica a ressalva de que o termo “zona de manejo”, do inglês *management zone*, pode ser entendido como um termo mais amplo, sendo sua delimitação utilizada para todo um pacote de manejo que não apenas a amostragem de solo e prescrição de fertilizantes, como apresentamos no livro Agricultura de Precisão (Molin; Amaral; Colaço, 2015), e que, por consequência, optamos por referenciá-la como “Unidade de Gestão Diferenciada (UGD)”. Assim, deixo claro que aqui neste texto me refiro às zonas para amostragem de solo.

A diferenciação entre os dois métodos de amostragem (grade *versus* zonas) é clara: sai-se de um cenário dependente de uma alta quantidade de amostras de solo, que podem gerar uma variação contínua de doses de fertilizante ao longo da lavoura, para um cenário onde uma única amostra, composta por

subamostras, poderia diagnosticar adequadamente a fertilidade de cada zona, ou seja, subentende-se que um valor médio para cada atributo do solo é o mais adequado para representar toda uma zona de manejo. Apresento, na Figura 1, um exemplo que compara os mapas resultantes de cada abordagem. Em outras palavras, esse método é um refinamento do método de amostragem ensinado nas disciplinas de fertilidade do solo e adubação dos cursos de Agronomia e afins, em que as áreas são divididas em glebas homogêneas e, em cada gleba, coletam-se subamostras que representarão uma amostra composta a ser enviada ao laboratório para o diagnóstico da fertilidade química. Entretanto, com as diversas opções de ferramentas digitais existentes hoje, essas glebas homogêneas (ou seja, zonas de amostragem) passam a ser virtuais e a ter diferentes formatos e tamanhos, não precisando seguir os limites “arbitrários” dos talhões ao longo das fazendas, mais ligados a questões logísticas.

Porém, tenho observado, ao longo dos anos, nas oportunidades de interação com os usuários em minhas palestras, treinamentos e consultorias, que falta clareza na comunidade da AP sobre um ponto crucial na delimitação das zonas de amostragem: para que a delimitação das zonas de manejo seja adequada para agrupar solos com características químicas semelhantes, é fundamental que as variáveis usadas para delimitar tais zonas tenham relação espacial com os atributos de solo. A possibilidade de camadas de informação (variáveis auxiliares) é ampla, como a condutividade elétrica aparente

do solo, mapas de produtividade, imagens de satélite, mapas topográficos, entre outros, mas a escolha correta entre essa vasta gama de opções é o que garantirá o retorno adequado dessa abordagem de prescrição de fertilizantes em doses variadas.

Há diversos protocolos e ferramentas para a construção/delimitação das zonas de manejo publicados na literatura científica (Castrignanò *et al.*, 2017; Córdoba *et al.*, 2016; Hamed Javadi; Guerrero; Mouazen, 2022; Jovanović *et al.*, 2025; Melo; Cunha; Amaral, 2025; Oldoni *et al.*, 2025; Paccioretti; Córdoba; Balzarini, 2020; Scudiero *et al.*, 2018; Sobjak *et al.*, 2024), embora haja poucos que focaram especificamente em zonas para amostragem de solo (Kerry *et al.*, 2024; Melo; Cunha; Do Amaral, 2026; Peralta; Costa, 2013; Valente *et al.*, 2024). Em suma, as etapas fundamentais são: 1) Escolha das variáveis auxiliares; 2) Análise de agrupamento (cluster) com padronização das variáveis para a mesma escala de valores; e 3) definição do número e/ou tamanho mínimo/máximo das zonas. Dessa forma, é natural que haja subjetividade e, de certa forma, baixa reprodutibilidade nos mapeamentos de zonas realizados; seu resultado depende fortemente do conhecimento técnico do analista/consultor e, em muitas situações, a consulta ao agricultor/técnico que conhece a lavoura se mostra fundamental para demarcar as zonas e levantar hipóteses sobre suas características. Tenho confiança de que, muitas vezes, sentar-se à mesa com o agricultor e mostrar-lhe algumas camadas de informação já permitiria uma boa delimitação de zonas desenhadas manualmente sobre um mapa de referência. As ferramentas digitais podem ajudar nisso, mas é pouco provável que consigam eliminar completamente a dependência do conhecimento tácito dos técnicos de campo, bem como da experiência e da sensibilidade do agricultor.

Retomando, o ponto central nessa estratégia de delimitação de zonas de amostragem reside na necessidade de haver correlações entre as variáveis auxiliares disponíveis (sejam de fontes gratuitas ou levantadas especificamente para isso) e os atributos de interesse do mapeamento. Não

tem sentido usar uma camada de informação para delinear as zonas se ela não tiver correlação real com os atributos que se quer medir (muitas das vezes são P, K, CTC e V% para recomendação dos fertilizantes fosfatados, potássicos e calcário). A pergunta que precisa ser feita é: esta variável realmente tem relação com ao menos um desses atributos? Se essa relação não existir, todo o serviço de amostragem e recomendação de fertilizantes em doses variadas pode ser comprometido.

Para quem já tem dados coletados, fica a provocação: faça um teste, relacione as variáveis, selecione as que têm alguma relação com os atributos do solo, aplique o procedimento de delimitação de zonas e verifique se elas seriam eficientes para agrupar pontos de solo com características semelhantes. A métrica de redução da variância (VR%) apresentada por Melo *et al.* (2025) é uma forma interessante de avaliar se as zonas contemplam adequadamente a variabilidade dos atributos do solo.

Para quem não tem dados disponíveis, por que não iniciar a investigação em uma área realizando uma amostragem esparsa? Considere 5 ou 10 hectares por amostra, preferencialmente em pontos que possam ser direcionados com base em variáveis auxiliares já disponíveis, para, na sequência, testar as relações entre as variáveis. Caso obtenha boas correlações, na próxima oportunidade de amostragem (safra seguinte), empregue a amostragem por zonas de forma mais assertiva. Inclusive, fica uma ressalva: se o solo for extremamente variável, uma zona de amostragem poderá abranger uma amplitude muito grande de valores dos atributos do solo, mas isso não quer dizer que a amostragem em grade seguida por interpolação dos dados seria melhor; tenho confiança de que “não seria”; também os provoco a realizarem esse teste! Obviamente esse material não esgota o assunto e assumo que a academia precisa gerar diretrizes claras para os usuários (estamos caminhando nisso), mas fica a provocação técnica




Figura 1. Área de produção de grãos composta por 10 talhões, totalizando aproximadamente 100 hectares: à esquerda, a grade amostral, com coleta de uma amostra de solo composta a cada 3 hectares; no centro, o mapa de CTC do solo após a interpolação dos dados; à direita, o mapa de CTC do solo gerado a partir de uma amostra composta de solo coletada em cada zona de amostragem.

Referências

- CASTRIGNANÒ, A.; BUTTAUFUOCO, G.; QUARTO, R.; VITTI, C.; LANGELLA, G.; TERRIBILE, F.; VENEZIA, A. A Combined Approach of Sensor Data Fusion and Multivariate Geostatistics for Delineation of Homogeneous Zones in an Agricultural Field. *Sensors*, v. 17, 12, 2017.
- CÓRDOBA, M. A.; BRUNO, C. I.; COSTA, J. L.; PERALTA, N. R.; BALZARINI, M. G. Protocol for multivariate homogeneous zone delineation in precision agriculture. *Biosystems Engineering*. v. 143, 2016.
- HAMED JAVADI, S.; GUERRERO, A.; MOUAZEN, A. M. Clustering and Smoothing Pipeline for Management Zone Delineation Using Proximal and Remote Sensing. *Sensors* v. 22, 2, 2022.
- JOVANOVIĆ, D.; GOVEDARICA, M.; GAVRILOVIĆ, M.; ČABILOVSKI, R.; VAN DER WAL, T. Multi-Source Data Integration for Sustainable Management Zone Delineation in Precision Agriculture. *Sustainability (Switzerland)*. v. 17, 15, 2025.
- KERRY, R.; INGRAM, B.; OLIVER, M.; FROGBROOK, Z. Soil sampling and sensed ancillary data requirements for soil mapping in precision agriculture I. delineation of management zones to determine zone averages of soil properties. *Precision Agriculture*, v. 25, 3, 2024.
- MELO, D. D.; CUNHA, I. A.; AMARAL, L. R. Precision Zones: An Open-Source QGIS Plugin for Management-Zone Segmentation in Precision Agriculture. *AgriEngineering*, v. 7, 12, 2025.
- MELO, D. D.; CUNHA, I. A.; AMARAL, L. R. Optimizing the number of subsamples for characterization of soil attributes in management zones. *Engenharia Agrícola*. v. 46, e20250063, 2026.
- MOLIN, J. P.; AMARAL, L. R.; COLAÇO, A. F. *Agricultura de Precisão*. São Paulo: Oficina de Textos, 2015.
- OLDONI, H.; MAGALHÃES, P. S. G.; OLIVEIRA, A. L. G.; LIMA, J. P.; FIGUEIREDO, G. K. D. A.; MORO, E.; AMARAL, L. R. Management zones delineation: a proposal to overcome the crop-pasture rotation challenge. *Precision Agriculture*, v. 26, 1, 2025.
- PACCIORETTI, P.; CÓRDOBA, M.; BALZARINI, M. FastMapping: Software to create field maps and identify management zones in precision agriculture. *Computers and Electronics in Agriculture*. v. 175, 2020.
- PERALTA, N. R.; COSTA, J. L. Delineation of management zones with soil apparent electrical conductivity to improve nutrient management. *Computers and Electronics in Agriculture*. v. 99, 2013.
- SCUDIERO, E.; TEATINI, P.; MANOLI, G.; BRAGA, F.; SKAGGS, T. H.; MORARI, F. Workflow to Establish Time-Specific Zones in Precision Agriculture by Spatiotemporal Integration of Plant and Soil Sensing Data. *Agronomy*, v. 8, 11, 2018.
- SOBJAK, R.; SOUZA, E. G. De; BAZZI, C. L.; HACHISUCA, A. M. M. AgDataBox-Map - A web application for creating thematic maps and management zones: users' evaluation. *Caderno Pedagógico*. v. 21, 12, 2024.
- VALENTE, D. S. M.; PEREIRA, G. W.; DE QUEIROZ, D. M.; ZANDONADI, R. S.; AMARAL, L. R.; BOTTEGA, E. L.; COSTA, M. M.; FREITAS COELHO, A. L.; GRIFT, T. Accuracy of Various Sampling Techniques for Precision Agriculture: A Case Study in Brazil. *Agriculture*, v. 14, 12, 2024.



VITIVINICULTURA DE PRECISÃO

Luís Henrique Basso¹

¹ Pesquisador, Embrapa Instrumentação, São Carlos - luís.basso@embrapa.br

A produção de uvas para vinho no Brasil (vitivinicultura) ocorre em três grandes regiões: no Sul e Sudeste do Brasil, sendo a mais antiga e tradicional; no Semiárido, valendo-se do uso da irrigação para a produção de vinhos tropicais; e em regiões do Sudeste, Centro-Oeste e Nordeste, para a produção de uvas com colheita em junho e julho, por meio da prática da dupla poda, e que origina os vinhos de inverno. Percebe-se então as variações que podemos encontrar nos vinhos produzidos no Brasil.

Em uma área agrícola, como os vinhedos ou parreirais, também podemos encontrar variações, tanto na área cultivada, ou seja, no espaço, como entre safra ou anos, isto é, no tempo. A grosso modo, a variação significa a mudança que uma característica ou propriedade do solo ou da planta pode apresentar, enquanto a variabilidade significa o padrão ou a extensão de uma variação em torno de um valor. Surgem então os termos variabilidade espacial e variabilidade temporal. Vale ressaltar que a viabilidade da aplicação da agricultura de precisão depende da existência de variabilidade.

Em relação à variabilidade espacial, para saber até onde e como ela ocorre, são realizados procedimentos como a coleta de medidas de uma ou mais características do solo e/ou da planta, conhecendo-se a sua localização por meio da latitude e longitude (georreferenciamento), e em alguns casos, a altitude pode ser útil para analisar a produção. Análises envolvendo técnicas estatísticas determinam a extensão dessa variabilidade, mostrando onde ela apresenta e não apresenta uma mudança significativa. Desse modo, são determinadas as zonas homogêneas, isto é, são as partes ou parcelas ou subáreas de uma área

agrícola onde uma característica apresenta valores que não são estatisticamente diferentes entre si, e onde uma amostra ou medida pode representar o seu comportamento em toda a área dessa zona. Mas esse valor difere do valor da característica em outra zona homogênea. Assim, as zonas homogêneas são a delimitação de zonas de uma área onde cada uma possui uma uniformidade em relação a uma característica ou mais. Deve-se ressaltar que a variabilidade é comumente percebida por viticultores, mesmo em vinhedos de menor dimensão ou entre vinhedos, e é um conhecimento que deve ser levado em consideração.

Quando as zonas homogêneas passam a ser utilizadas para que a realização de uma prática agrícola seja realizada de modo diferenciado entre elas, levando em consideração a variabilidade, surge o termo zonas de manejo, que pode ser chamado de unidade de gestão. A zona de manejo pode considerar zonas homogêneas de diferentes características, que realmente influenciem a produção.

Em relação à variabilidade temporal, as zonas de manejo devem ser estáveis ao longo do tempo. Por isso, as características relacionadas à produtividade, e escolhidas para representar a variabilidade, não devem apresentar alterações frequentes ao longo das safras ou anos. Caso isso aconteça, dificulta o uso da agricultura de precisão.

Na viticultura de precisão, ou no caso específico da produção de uvas para vinho, vitivinicultura de precisão, os dados relacionados à fertilidade (pH, quantidade de nutrientes e matéria orgânica), física do solo (textura, retenção de água, profundidade),

desenvolvimento e produção da planta e composição das bagas têm sido utilizados para a delimitação de zonas homogêneas, as quais podem se tornar zonas de manejo.

Uma forma de praticar a vitivinicultura de precisão é por meio da colheita seletiva, de acordo com as zonas de manejo definidas, que mostram as características que influenciam a composição de uvas e, conseqüentemente, nos vinhos. As uvas colhidas em diferentes zonas são vinificadas separadamente, podendo-se realçar o potencial enológico do *terroir* do vinhedo ou entre vinhedos de uma mesma cultivar. Isso auxilia a definir se os vinhos elaborados serão jovens ou de guarda ou de corte (ou blend ou assemblage), a partir dos diferentes potenciais identificados nas zonas de manejo e que orientaram a colheita seletiva. As zonas de manejo com base em características do solo e/ou da planta podem também orientar onde realizar a amostragem de solo e de folhas e bagas para análise; aplicar doses maiores ou menores de corretivos e fertilizantes; instalar ou utilizar sensores de solo e plantas; e até variar o tempo de irrigação e, conseqüentemente, a lâmina de água, com base nas diferenças identificadas na extensão do vinhedo ou entre vinhedos.

A variabilidade das videiras pode ser conhecida pelo sensoriamento remoto. Podem ser usadas imagens de satélite ou obtidas por

veículos aéreos não tripulados (drone), com as quais são calculados índices de vegetação, utilizados para avaliar o crescimento e desenvolvimento das plantas. Também existem sensores que podem ser utilizados para medição, por exemplo, do teor de água ou clorofila (e indiretamente do nitrogênio) nas folhas, que apresentam relação com o desenvolvimento das plantas. A variabilidade do solo pode ser conhecida medindo-se a sua condutividade elétrica aparente (CEa), cujo comportamento depende da composição química, textura, umidade e profundidade do solo. Mapas com zonas homogêneas de CEa podem orientar onde realizar amostragens de solo para uma avaliação mais detalhada sobre o solo.

A vitivinicultura de precisão não tem como foco aumentar a produtividade, mas sim identificar as partes de um vinhedo ou também entre vinhedos que podem apresentar diferenças entre si, o que pode viabilizar manejos de acordo com o tamanho de cada zona. Isso também pode contribuir para a enologia de precisão, que consiste na elaboração de vinhos distintos e compatíveis com cada zona de manejo. É uma estratégia que valoriza o potencial enológico e a tipicidade de um ou mais vinhedos, o que pode agregar valor ao vinho.



EXPERIMENTAÇÃO ON-FARM: CONCEITOS E APLICAÇÕES NA TOMADA DE DECISÃO AGRONÔMICA

André Freitas Colaço¹

¹ Professor, Escola Superior de Agricultura 'Luiz de Queiroz' (ESALQ), Universidade de São Paulo (USP) – ande.colaco@usp.br

Desde o surgimento da agricultura de precisão (AP), grandes avanços tecnológicos têm ocorrido na área de coleta de dados e em sistemas de automação em máquinas agrícolas. Dentre as tecnologias mais relevantes destacam-se o monitoramento de produtividade, o mapeamento da fertilidade do solo, ferramentas de sensoriamento de solo e plantas, além de tecnologias de automação, como controladores de taxa variável, piloto automático, entre outras.

Apesar desse progresso tecnológico, a etapa de tomada de decisão agronômica ainda permanece, em grande medida, ancorada em ferramentas tradicionais, como tabelas de recomendação de fertilizantes desenvolvidas a partir de experimentação agronômica clássica. Isso ocorre inclusive nas aplicações em taxa variável, nas quais os dados utilizados como entrada para a recomendação são locais, mas são inseridos em regras de decisão genéricas e simplificadas, que nem sempre refletem adequadamente a complexidade do sistema produtivo local. Esse descompasso entre a sofisticação dos dados disponíveis e a simplicidade das regras de decisão representa uma limitação importante para o pleno aproveitamento das tecnologias digitais e abordagens de gestão associadas à AP.

Nesse contexto, a experimentação *on-farm* surge como uma abordagem transformadora, pois permite a geração de conhecimento local sobre a resposta do sistema produtivo a diferentes estratégias de manejo. Esse conhecimento pode subsidiar a tomada de decisão de forma mais assertiva,

adaptando as práticas às condições específicas de cada área e safra e, conseqüentemente, alinhando-as aos princípios e expectativas da AP.

Conceitos da experimentação on-farm

A experimentação *on-farm* é conhecida por diferentes terminologias na literatura internacional, incluindo *on-farm experimentation* (OFE), *on-farm precision experimentation* e *farmer-centric on-farm experimentation*, também associada às abordagens de experimentação centradas no produtor. Em português, são utilizadas expressões como “experimentação de precisão” ou “experimentação em nível de fazenda”, sendo “experimentação *on-farm*” o termo mais consolidado atualmente.

De forma geral, a experimentação *on-farm* consiste em uma abordagem experimental baseada na condução de ensaios em larga escala, realizados sob condições reais de produção. Esses experimentos empregam delineamentos espacialmente distribuídos e fazem uso, em maior ou menor grau, de ferramentas e tecnologias digitais e de AP para sua implementação, monitoramento e avaliação.

Seu principal objetivo não é exclusivamente o avanço do conhecimento científico como na experimentação clássica, mas sim a geração de conhecimento local aplicado à tomada de decisão agronômica.

Essa abordagem se insere também em um contexto mais amplo de pesquisa participativa e inovação centrada no usuário, no qual há maior integração entre pesquisadores e produtores. Esse paradigma contrasta com modelos tradicionais de pesquisa *top-down*, promovendo maior transdisciplinaridade e visão sistêmica na geração de conhecimento.

A experimentação agrônômica clássica é caracterizada por ensaios conduzidos em áreas pequenas, com alto grau de controle experimental e busca de uniformidade ambiental. Seu principal objetivo é isolar o efeito de tratamentos específicos, utilizando delineamentos estatísticos bem definidos e rigorosos.

Embora esse modelo apresente elevado rigor científico, ele possui limitações operacionais, incluindo maior dependência de trabalho manual e menor representatividade das condições reais de produção. Além disso, os resultados obtidos frequentemente refletem condições médias, não capturando adequadamente a variabilidade espacial existente em áreas comerciais.

Por outro lado, a experimentação *on-farm* ocorre em larga escala, utilizando maquinário agrícola comercial e sendo incorporada às operações normais da fazenda. Ela explora a variabilidade espacial do talhão e permite a coleta de dados em condições reais de produção, com menor controle experimental, porém maior representatividade prática.

Assim, enquanto a experimentação clássica é orientada principalmente à geração de conhecimento científico generalizável, a experimentação *on-farm* é tipicamente orientada à tomada de decisão local e ao suporte direto ao manejo agrônômico.

Delineamentos experimentais

Seguindo sua natureza prática e pragmática, experimentos *on-farm* são tipicamente conduzidos em larga escala e implementados utilizando as máquinas e operações agrícolas rotineiramente empregadas pelos produtores. Os delineamentos experimentais mais comuns baseiam-se em faixas (*strip trials*) ou parcelas, com diferentes níveis de replicação, buscando conciliar rigor experimental e viabilidade operacional.

Além desses delineamentos, abordagens experimentais mais simples também podem ser empregadas, como a divisão do talhão em grandes áreas destinadas a diferentes tratamentos (por exemplo, metade do talhão para cada tratamento) ou mesmo a aplicação de tratamentos distintos em talhões inteiros. Nesses casos, a menor replicação é compensada por uma escala de análise ainda maior, na qual a propriedade agrícola pode ser tratada como um "grande experimento", com os tratamentos distribuídos entre diferentes talhões e a inferência baseada na variabilidade existente entre eles.




Figura 1. Tipos comuns de delineamentos experimentais: em faixa ou parcelas, com menor ou maior grau de replicação.

Além da escolha do tipo de unidade experimental (faixas ou parcelas), o planejamento completo de experimentos on-farm deve considerar:

- a variabilidade espacial da área e zonas de manejo, para o melhor posicionamento das faixas ou parcelas;
- o número de tratamentos e tipo de manejo avaliado;
- o nível de replicação espacial;
- características operacionais, como largura de equipamentos;
- a resolução espacial dos sistemas de coleta de dados.

De maneira geral, o produtor e/ou o agrônomo responsável pelo planejamento dos experimentos deve adotar critérios que favoreçam comparações confiáveis entre os

tratamentos e minimizem o erro experimental. No caso de experimentos em faixas, por exemplo, é desejável que as faixas sejam posicionadas de forma a atravessar diferentes zonas de manejo ou gradientes de variabilidade, permitindo capturar a heterogeneidade espacial da área. Ao mesmo tempo, deve-se buscar minimizar a variabilidade no sentido transversal às faixas, de modo que os tratamentos sejam comparados sob condições semelhantes ao longo de sua extensão. Em outras palavras, busca-se que o experimento represente a variabilidade existente na área, mas as unidades experimentais sendo comparadas devem estar posicionadas em locais com condições suficientemente homogêneas para que as diferenças observadas possam ser atribuídas, predominantemente, aos tratamentos e não à variabilidade inerente do ambiente.




Figura 2. Posicionamento de um experimento em faixas de acordo com a distribuição espacial de zonas de manejo




Figura 3. Posicionamento de um experimento em faixas e em parcelas de acordo com a distribuição espacial de zonas de manejo.

Tecnologias para implementação e monitoramento de experimentos on-farm

A implementação de experimentos *on-farm* é favorecida por tecnologias digitais embarcadas típicas da AP. Entre as principais tecnologias destacam-se:

- **Aplicação em taxa variável**, essencial para implementar diferentes doses conforme o delineamento experimental, além de gerar arquivos *as-applied*, fundamentais para rastreabilidade e análise;
- **Piloto automático**, que garante precisão espacial na execução dos delineamentos, assegurando alinhamento adequado das faixas ou parcelas;
- **Monitores de produtividade**, principais fontes de dados de resposta dos experimentos;
- **Sensoriamento remoto e imageamento de culturas**, utilizados como alternativa ou complemento ao monitor de produtividade, com base em indicadores de vigor vegetativo;
- **Dados de sensoriamento e outras camadas adicionais de informação**, camadas como condutividade elétrica aparente do solo, atributos de relevo, entre outras variáveis, são importantes para a análise dos resultados, pois facilitam a explicação das diferentes respostas observadas ao longo da extensão da área experimental.

Preparação de dados e análise

A etapa de análise exige um processo cuidadoso de fusão de dados (*data fusion*), integrando informações de aplicação (*as-applied*), delineamento experimental e dados de resposta. Essa integração requer a construção de um banco de dados centralizado e espacialmente consistente, o que pode ser desafiador devido às diferentes resoluções espaciais e temporais dos sistemas envolvidos. Uma vez estruturado esse banco de dados, as análises podem seguir diferentes abordagens, dependendo do objetivo experimental.

As análises em experimentação *on-farm* podem ser agrupadas em duas categorias principais:

- **Regressão:** Aplicada quando os tratamentos envolvem variáveis contínuas, como doses de fertilizantes ou densidade de semeadura. Nesse caso, busca-se modelar a resposta da cultura em função da dose aplicada, permitindo a estimativa de doses ótimas ao longo do talhão.
- **Comparação de tratamentos:** Utilizada quando os tratamentos são categóricos, como diferentes variedades ou sistemas de manejo. Nesse caso, o objetivo é comparar desempenhos entre grupos, frequentemente com base em testes de significância estatística.

Uma característica central da experimentação *on-farm* é a possibilidade de análise em múltiplas escalas espaciais. Ao contrário de abordagens tradicionais que frequentemente produzem um único resultado agregado por experimento, a experimentação *on-farm* permite avaliar respostas:

- por zonas de manejo;
- ao longo de faixas experimentais;
- ou em alta resolução espacial ao longo de todo o talhão.

Essa característica aumenta significativamente o valor informacional dos experimentos, permitindo inferências mais detalhadas sobre a variabilidade de resposta ao manejo.

Aplicação

O exemplo abaixo apresenta um mapa de recomendação de fertilização nitrogenada em taxa variável. Sobreposto ao mapa, observa-se um experimento simples em faixas, composto por três tratamentos: uma faixa com elevada dose de nitrogênio, uma com dose padrão e outra com baixa dose de aplicação. Também é apresentada uma análise baseada em regressão com janela móvel ao longo das faixas experimentais, permitindo estimar localmente a resposta da cultura à adubação nitrogenada e a dose ótima, que maximizou a lucratividade.

Os resultados dessa análise são representados pelos pontos coloridos distribuídos ao longo das faixas, nos quais é mostrada a dose ótima de nitrogênio para cada posição do experimento. Essa simples abordagem experimental e analítica permite comparar as doses utilizadas na aplicação em taxa variável com as doses ótimas estimadas a partir dos experimentos. Dessa forma, o produtor pode avaliar quão próxima sua

recomendação anterior esteve da condição ideal, validando sua estratégia de manejo e, ao mesmo tempo, gerando conhecimento específico sobre a resposta das diferentes regiões do talhão à aplicação de nitrogênio. Esse processo de aprendizado possibilita o refinamento contínuo das recomendações futuras, tornando-as progressivamente mais adaptadas às características locais do sistema de produção.




Figura 4. Exemplo de um experimento de N em faixas e comparação de doses aplicadas e doses ótimas de nutriente.

Conclusões

Os principais resultados da experimentação *on-farm* decorrem da observação da resposta da cultura a alterações no manejo. Essas alterações podem envolver, por exemplo, diferentes doses de fertilizantes, sementes ou outros insumos, a utilização de distintos produtos (fertilizantes, fitossanitários, etc.) ou a adoção de diferentes práticas de manejo do solo. A partir desses experimentos, é possível quantificar a resposta da cultura aos tratamentos e estimar a dose ou o manejo ótimo para cada talhão ou mesmo para diferentes zonas dentro de um mesmo talhão.

As informações obtidas podem ser utilizadas tanto para validar decisões de manejo previamente adotadas — por exemplo, verificando se a dose de fertilizante recomendada foi próxima da economicamente ou agronomicamente ótima — quanto para gerar conhecimento local que subsidie decisões futuras mais assertivas. Dessa forma, a experimentação *on-farm* transforma dados gerados na própria área de produção em evidências capazes de apoiar recomendações de manejo cada vez mais adaptadas às condições específicas de cada sistema produtivo.



MAPAS DE PRODUTIVIDADE DE SOJA EM OPERAÇÕES CONDUZIDAS COM MÚLTIPLAS COLHEDORAS: ESTRATÉGIA DE OPERAÇÃO E PROCESSAMENTO DE DADOS

Rodrigo Sinaidi Zandonadi¹

¹ Professor, Universidade Federal de Mato Grosso, campus de Sinop - rodrigo.zandonadi@ufmt.br

Estudos do uso de mapas de produtividade no Brasil podem ser encontrados no final da década de 90 relacionados a estudos realizados em lavoura de milho (Balastreire et al., 1997 apud Eitelwein et al., 2016). Nas safras 2013/2014 e 2014/2015, um levantamento conduzido em regiões de grande destaque na produção de soja em Mato Grosso relata que 27% das máquinas avaliadas estavam equipadas com sistema de direcionamento automático e com sistemas de mapeamento de produtividade (SMP), mas não eram utilizados nas operações (Zandonadi e Rufato 2021). Relatos da não utilização da ferramenta revelavam dificuldade em conduzir as calibrações necessárias dos sensores e falta de habilidade e de ferramentas para o devido processamento e tratamento de dados para a geração dos mapas. Desde então, o grupo de pesquisa LAPMec (Laboratório de Agricultura de Precisão e Mecanização - UFMT, Sinop) vem conduzindo trabalhos em parceria com produtores, buscando soluções em processos que viabilizem a utilização de SMPs para a geração de mapas tecnicamente viáveis, principalmente na cultura de soja da região norte e médio-norte de Mato Grosso.

Ao mesmo tempo, o avanço em sistemas de conectividade, viabilizando o acesso à telemetria de dados, aliado às plataformas digitais para o gerenciamento das informações, facilitou substancialmente um dos grandes entraves: acessar e gerenciar os dados gerados pela máquina, especialmente

quando se trata de operações com múltiplos equipamentos trabalhando simultaneamente. No entanto, conectividade ainda não é regra nos campos de produção (especialmente em regiões do centro-oeste) e mesmo em operações onde conectividade e telemetria são uma realidade, a prioridade é dada ao monitoramento de questões operacionais das máquinas em campo, ficando os dados agrônômicos coletados (ex. SMP) muito aquém da qualidade necessária para uso efetivo. As dificuldades impostas pelos processos de calibração de sensores, associadas às características críticas das lavouras de soja no período de colheita nas lavouras mato-grossenses devido à época com altos índices pluviométricos, continuam causando problemas, assim como o padrão de organização da operação de colheita.

Diante do exposto, o objetivo desta nota técnica foi apontar os principais problemas que afetam o uso dos SMPs e apresentar o resultado de um estudo de caso realizado utilizando procedimento para contornar os problemas apontados.

Calibração do sensor de fluxo de massa:

Recomenda-se que seja feita a calibração deste sensor no início da colheita de cada cultura e refazer calibrações sempre que mudar de variedade/híbrido ou ainda, mudança significativa na umidade do produto. No caso das lavouras mato-grossenses, a dinâmica de

operação dificulta a aplicação dessas recomendações. Várias máquinas trabalham juntas no mesmo talhão, pois a janela para a semeadura da segunda safra é curta, o que demanda uma operação de colheita rápida. Nesse cenário, vários talhões podem ser trabalhados em um mesmo dia e, conseqüentemente, várias variedades demandam novas calibrações.

A umidade também influencia a resposta dos sensores de fluxo de massa (majoritariamente sensores do tipo prato de impacto), embarcados nas colhedoras, pois altera as propriedades físicas dos grãos, assim como a relação massa-volume. O sensor de umidade, se corretamente calibrado, proporciona a compensação para a umidade padrão, mas não consegue compensar ou corrigir a influência que a alteração das propriedades físicas causa na resposta do sensor, sendo necessárias calibrações dos sensores de fluxo para diferentes faixas de umidade do grão que está sendo colhido.

Embora o processo de calibração do sensor de fluxo de massa não seja complexo, realizar o processo várias vezes ao dia em todas as máquinas da frota causa grande transtorno na operação, especialmente em épocas em que a jornada de trabalho efetivo disponível (devido às condições climáticas) pode ser de apenas 2,5 a 3,0 h.dia¹ (Koellen e Zandonadi, 2018).

Calibração do sensor de umidade:

O sensor de umidade também deve ser calibrado, obviamente, conforme a variação do padrão de umidade do produto. Embora o procedimento de calibração do sensor de umidade seja bem mais simples (quando comparado ao fluxo de massa), ainda assim é

um transtorno, pois demandaria constantes mensurações de umidade com um equipamento de referência. Outra questão é que o sensor pode apresentar comportamento errático e, quando a calibração é feita no meio de um trabalho, fica-se sem saber se o comportamento mudou por conta de uma recalibração ou qualquer outro motivo que tenha interferido no sistema.

Organização da frota:

Um dos grandes desafios para se trabalhar com dados de produtividade em lavouras de soja do Mato Grosso é a forma de organização da frota de colheita em operação. Muitas das propriedades não usam veículo transbordo (carretões) na colheita de soja, o que, além de baixar consideravelmente a eficiência de campo das colhedoras, pode favorecer o aumento das perdas de grãos e comprometer a qualidade dos mapas de produtividade. Na Figura 1A, observa-se uma imagem aérea que exemplifica uma operação de colheita sem suporte logístico (carretões), com manobras fora da área de cabeceira e com largura de plataforma inadequada. Essa situação dificulta consideravelmente o tratamento dos dados gerados pelo SMP, pois as máquinas podem não estar sujeitas às mesmas variações de produtividade, já que trabalham majoritariamente em áreas distintas de um mesmo talhão. Na Figura 1B é apresentado um mapa com a distribuição de quatro máquinas na operação de colheita, verificando-se que não existiu uma sequência organizada de faixas de trabalho. Essa situação é na verdade a maior dificuldade para o que está sendo proposto nessa nota técnica.




Figura 1. Operação de colheita de soja sem o devido planejamento (A) Posição das diferentes máquinas dentro do talhão (B) .

Procedimento adotado:

A Fazenda Gobbi (Tabaporã-MT), faz o uso de transbordo nas operações de colheita de soja atingindo alto nível de eficiência de campo (Kollen e Zandonadi 2018) e permitindo que as máquinas trabalhem em pistas adjacentes sequenciais, conforme imagem apresentada na Figura 2. Essa organização faz com que as máquinas trabalhem sempre em regiões próximas entre si, ou seja, estejam sujeitas às mesmas (ou pelo menos semelhantes) variações de produtividade no espaço. Isso permite que, caso exista diferença na média de produtividade entre as máquinas, se faça a normalização dos dados utilizando a média geral do talhão, de modo que a média de todas as máquinas se iguale à média geral do talhão. B.



Figura 2. Colheita de soja realizada com a mesma orientação das linhas da cultura (Fazenda Gobbi, Tabaporã - MT), em faixas adjacentes sequenciais.

Resultados:

A operação de colheita da safra 25/26 da Fazenda Gobbi foi conduzida com cinco colhedoras John Deere, sendo duas STS9770 e três S770, todas equipadas com SMP e conectadas à plataforma *Operations Center*. Os dados foram exportados da plataforma no formato .shp e reprocessados utilizando algoritmos desenvolvidos no programa Matlab (The MathWorks.2024).

O procedimento de filtragem e normalização pela média do talhão foi realizada e os resultados são apresentados em três exemplos a seguir: (i) Máquinas com variação de dados semelhantes entre si; (ii) Máquinas apresentando discrepância no padrão de variação de dados e (iii) Mapa geral de produtividade geral da fazenda.

Máquinas com variação de dados semelhante entre si

Os dados brutos de produtividade (apenas com extremos filtrados para velocidade, umidade, largura e produtividade) de um talhão de 147,4 ha são apresentados na Figura 3A, e a organização das máquinas (faixas trabalhadas) pode ser verificada na Figura 3B. Na Figura 3C, são apresentados os dados de produtividade filtrados por máquina, utilizando limites estatísticos (média $\pm$ 2,5 desvios-padrão), com descarte da região de cabeceira, enquanto na Figura 3D é apresentado o mapa de produtividade normalizado pela média do talhão.

Os gráficos de caixas com dados de produtividade agrupados por máquina são apresentados na Figura 4, na qual se observa o comportamento dos dados após a filtragem de

pontos extremos, a aplicação de um filtro estatístico e a normalização dos dados pela média do talhão, respectivamente.




Figura 3. Mapa de produtividade de soja com pontos extremos filtrados (A); mapa mostrando a organização das máquinas no talhão (B); dados de produtividade após a aplicação do filtro estatístico e o descarte da área de cabeceira (C); e dados normalizados pela média do talhão (D).




Figura 4. Gráficos de caixas com dados de produtividade agrupados por máquina, com apenas dados extremos filtrados, filtro estatístico e dados normalizados pela média, respectivamente.

Observe que a faixa entre os percentis 25 e 75 das máquinas 35 a 95 (Figura 4C) é muito parecida e que, embora as máquinas 31 e 34 apresentem uma faixa um pouco maior (dos percentis 25 a 75), ainda é um comportamento que não prejudica a estratégia de normalização. De fato, o mapa de produtividade normalizado (Figura 3D) permite identificar diferentes padrões de produtividade no talhão, o que é impossível de identificar a partir dos dados apenas filtrados (Figura 3C).

Máquina com discrepância no padrão de variação de dados

Os dados apresentados na Figura 5 são referentes a um talhão de 51.3 ha em que uma

das máquinas apresentou discrepância no padrão da variação de dados de produtividade. Os gráficos de caixas com dados de produtividade agrupados por máquina são apresentados na Figura 6 onde pode ser observado o comportamento dos dados após filtragem de pontos extremos, aplicação de filtro estatístico e normalização de dados pela média do talhão.

Observe que a máquina 95 apresenta uma faixa de percentis de 25 a 75, discrepante em relação às outras máquinas. Observando o mapa (Figuras 5B e 5D), é possível identificar que as anomalias nos dados de produtividade após a normalização coincidem com a máquina 95.

A seguir, são apresentados os resultados de produtividade agrupados por

máquina (Figura 7A) e o mapa de produtividade (Figura 7B), após o descarte da máquina 95, evidenciando a melhora na representação espacial do padrão de produtividade no talhão.

Note que as faixas sem informação (devido ao descarte de dados) podem ser

facilmente interpoladas caso necessário. Observe que, se a máquina 95 tivesse trabalhado em uma parte do talhão, longe das outras máquinas, perderia a referência e o padrão errático dos dados de produtividade poderia ser interpretado como um problema no campo.




Figura 5. Mapa de produtividade de soja com pontos extremos filtrados (A); mapa mostrando a organização das máquinas no talhão (B); dados de produtividade aplicados o filtro estatístico e descarte de área de cabeceira (C) e dados normalizados pela média das máquinas (D).




Figura 6. Gráficos de caixas com dados de produtividade agrupados por máquina, com extremos filtrados, filtro estatístico e dados normalizados pela média das máquinas, respectivamente.




Figura 7. Gráficos de caixas com dados de produtividade normalizados e mapa de produtividade após descarte da máquina 95 em (A) e (B), respectivamente.

Mapa geral da fazenda.

O processamento automático de todos os talhões da fazenda foi realizado após ajustar os parâmetros de filtragem de dados e descarte de máquinas que apresentavam algum tipo de anomalia nos dados gerados (ex.: máquina 95 apresentada acima). O mapa geral de produtividade de soja 25/26 apenas filtrado e

filtrado normalizado é apresentado na Figura 8 A e B, respectivamente, ambos com áreas de cabeceira descartadas. Pode-se observar que as anomalias nos padrões de produtividade foram minimizadas após o tratamento. Note nos talhões enumerados (1 a 8) que as “listras” avermelhadas deixaram de ser observadas após a normalização dos dados. Nas Figuras 9A a D,

são apresentados os talhões números 5 e 1 (da Figura 8) com mais detalhes, mudança nos padrões de produtividade, ficando mais

evidentes a regiões de alta e baixa produtividade dentro dos talhões.




Figura 8. Mapa colheita de soja 25/26 Fazenda Gobbi gerados a partir de dados filtrados (A) e dados filtrados e normalizados (B)




Figura 9. Mapas de produtividade apenas filtrados dos talhões 5 e 1 nas Figuras (A) e (C), respectivamente; e mapas de produtividade normalizados dos talhões 5 e 1 nas Figuras (B) e (D), respectivamente.

Conclusões

Foi apresentado um exemplo prático de como trabalhar com mapas de produtividade na cultura de soja em uma operação envolvendo múltiplas máquinas operando dentro dos talhões. Máquinas sempre trabalhando em pistas adjacentes permitem que a frota opere em condições semelhantes quanto à variabilidade de produtividade ao longo do talhão. Essa condição favorece a normalização dos dados de cada SMP, utilizando a média final do talhão, minimizando os erros de padronização da produtividade dos talhões trabalhados e produzindo mapas de melhor qualidade, mesmo com a calibração dos sensores apenas no início da safra.

Agradecimentos: Fazenda Gobbi por viabilizar o estudo e disponibilização de dados.

Referências

EITELWEIN, M. T.; SANTI, A. L.; GIOTTO, E.; DAMIAN, J. M.; CHERUBIN, M. R.; CORASSA, G. M.; BASSO, C. J.; FLORA, L. P. D. Mapeamento da produtividade de grãos e utilização dos mapas. In: SANTI, L. S.; SEBEM, E.; GIOTTO, E.; AMADO, T. J. C. (Orgs). Agricultura de Precisão no Rio Grande do Sul. 1 ed. Santa Maria, RS: CESPOL, 2016, cap. 5, p. 99-119.

KOELLN, F. H. B.; ZANDONADI, R. S. Estudo da logística na colheita mecanizada de soja, na região do noroeste mato-grossense. Em: 1º Simpósio mato-grossense de mecanização agrícola e agricultura de precisão- SIMAP. Sinop-MT, 2018.

THE MATHWORKS. MATLAB: versão 24.2.0 (R2024b). Natick: The MathWorks, Inc., 2024.

ZANDONADI, R.S. Sistema de Mapeamento de produtividade nas

colhedoras de grãos - Boas Práticas. Fichas Técnicas, v. 1, p. 1, 2021. Disponível em: <https://mtciencia.com.br/fichas-tecnicas-2/>. Acessado em 23/06/2026

ZANDONADI, R.S.; RUFFATO, S. Colheita mecanizada de soja no Mato Grosso: Perdas devido ao desempenho das colhedoras e aspectos operacionais. Research, Society and Development. v. 10, n.5. 2021.



ÍNDICE DE VEGETAÇÃO POR DIFERENÇA NORMALIZADA (NDVI) E SUAS APLICAÇÕES NA AGRICULTURA

André Luis Vian¹; Christian Bredemeier¹

¹ Professor, Faculdade de Agronomia, Grupo de Estudos em Agricultura Digital (GEAD), Universidade Federal do Rio Grande do Sul (UFRGS). – andre.vian@ufrgs.br; bredemeier@ufrgs.br

O Índice de Vegetação por Diferença Normalizada (NDVI) é um dos índices de vegetação de maior utilização para o monitoramento remoto da vegetação. Esse índice é calculado a partir da diferença entre a luz vermelha absorvida pelas plantas e a luz do infravermelho próximo refletida por elas, permitindo avaliar a atividade fotossintética e o vigor da cultura. Quanto maior o valor do NDVI, maior tende a ser a biomassa e a saúde das plantas, enquanto valores baixos podem indicar estresse hídrico, deficiência nutricional ou outros problemas.

No contexto da agricultura de precisão e digital atual, o NDVI desempenha um papel fundamental ao permitir o acompanhamento detalhado das lavouras ao longo do ciclo produtivo. Por meio de sensores embarcados em satélites, drones ou dispositivos portáteis, os agricultores podem monitorar grandes áreas de cultivo de forma rápida e eficiente, identificando variações no desenvolvimento das plantas e possibilitando a identificação de variabilidade e de proposição de medidas corretivas. A aplicação do NDVI na tomada de decisão contribui para um manejo agrícola mais

assertivo, auxiliando na detecção precoce de anomalias, no ajuste da adubação e da irrigação e na delimitação de áreas com potencial produtivo diferenciado. Dessa forma, a tecnologia não apenas melhora a eficiência operacional, mas também promove o uso mais sustentável dos recursos naturais, reduzindo desperdícios e impactos ambientais.

Mas de onde vem o NDVI?

Os índices de vegetação são “construídos” a partir da reflectância dos comprimentos de onda de diferentes porções do espectro eletromagnético, como das regiões do visível e do infravermelho próximo, onde se obtém informações sobre a estrutura e vigor da vegetação (Figura 1). Na região do visível (entre 400 e 680 nm aproximadamente), as principais estruturas que interagem com a radiação são os pigmentos de absorção da energia incidente (clorofila, antocianina, xantofila). Já na região do infravermelho próximo (NIR), as principais variáveis que afetam a quantidade de energia refletida são a biomassa de parte aérea, o índice de área foliar e quantidades de celulose, lignina e água presentes no dossel vegetativo. Com base nessas informações, é possível inferir sobre o crescimento e o desenvolvimento das plantas ao longo do ciclo.




Figura 1. Curva espectral característica da vegetação e as interações das faixas espectrais com compostos de plantas. Adaptado de Hank et al. (2019).

O Índice de Vegetação por Diferença Normalizada (NDVI) é um indicador quantitativo derivado de medições espectrais, fundamentado na resposta da vegetação à radiação eletromagnética em comprimentos de onda específicos. O NDVI é calculado a partir das informações de reflectância da vegetação com a seguinte equação:

$$NDVI = \frac{(NIR - Red)}{(NIR + Red)}$$

onde: *NIR* representa a reflectância no infravermelho próximo (aproximadamente 700–900 nm) e *Red* a reflectância na faixa do vermelho (cerca de 640–700 nm).

A vegetação saudável exibe elevada absorção na região do vermelho, decorrente da presença de clorofila, e acentuada reflectância no NIR, decorrente da estrutura celular e da morfologia foliar. Esse contraste espectral permite diferenciar áreas com cobertura vegetal ativa daquelas com solo exposto ou corpos d'água, que apresentam respostas espectrais menos dinâmicas nessas bandas. O índice varia numericamente de -1 a +1, sendo que valores superiores a 0,2 geralmente indicam presença de vegetação, enquanto valores mais próximos a zero ou negativos sugerem áreas com solo ou água (Jackson; Huete, 1991).

Proposta inicialmente por Kriegler et al. (1969), e consolidada a partir da década de 1970, a metodologia do NDVI destacou-se pela

capacidade de delimitar vegetação e identificar estresses precocemente, característica que a tornou relevante para agricultura comercial e em estudos de uso do solo. Essa aplicabilidade ampliou-se com o advento de sistemas de sensoriamento remoto capazes de gerar dados em múltiplas resoluções espaciais e temporais (Huang et al., 2020). Sensores embarcados em plataformas orbitais ou aéreas capturam dados brutos, que, após correções radiométricas e processamento, são convertidos no índice, subsidiando decisões em manejo agrícola (Jensen, 2007; Campbell; Wynne, 2011).

De quais plataformas podemos obter o NDVI?

A obtenção dos dados utilizados para o cálculo do NDVI pode ser realizada por meio de diferentes plataformas, cada uma oferecendo vantagens específicas em termos de resolução espacial, temporal e espectral. Sensores orbitais, como os acoplados aos satélites Landsat, Sentinel-2, MODIS, Planet Scope, entre outros, oferecem cobertura global e históricos de longo prazo, com resoluções espaciais que variam de 3 a 5 m (Planet Scope) a 250 m (MODIS), ideais para monitoramento em escala regional (Lillesand et al., 2015). Suas órbitas são sincronizadas com o ciclo solar para garantir uniformidade nas condições de imageamento.

Veículos aéreos não tripulados (VANTs) equipados com câmeras multiespectrais destacam-se na agricultura de precisão pela capacidade de fornecer imagens com alta resolução espacial e flexibilidade na coleta de dados, permitindo a obtenção de informações detalhadas sobre o estado das culturas em áreas específicas. Essas plataformas capturam imagens em bandas espectrais estreitas, permitindo gerar NDVI com detalhamento suficiente para identificar variabilidade do crescimento das plantas dentro do talhão e detecção de estresses (Zhang; Kovacs, 2012). A integração com algoritmos de processamento viabiliza correções radiométricas em tempo real, minimizando distorções por variações de altitude e ângulo de captura (Colomina; Molina, 2014).

Por fim, sensores portáteis, como GreenSeeker e SpectraVue, permitem coletas *in situ*, vinculando o valor do NDVI a parâmetros agrônômicos, como índice de área foliar e teor de nitrogênio da cultura. Baseados em emissão de luz por LEDs ou lasers nas bandas do vermelho e NIR, garantem alta acurácia pontual, sendo fundamentais para calibração de dados remotos e validação de modelos preditivos (Baret et al., 2007). Embora restritos à escala local, sua portabilidade os torna indispensáveis para diagnósticos localizados.

Principais aplicações do NDVI na agricultura

As possibilidades de aplicação do NDVI são inúmeras e têm sido fundamentais para o desenvolvimento da agricultura de precisão no Brasil, permitindo o manejo eficiente de grandes lavouras, especialmente em um país de dimensões continentais como o nosso, onde a

agricultura desempenha papel crucial na economia e torna o país um dos maiores produtores de alimentos no cenário mundial (Epiphany et al., 2010).

Assim como já mencionado, o NDVI se relaciona com a quantidade de clorofila e de biomassa das culturas e tudo o que interfere de forma direta e/ou indireta é possível de ser medido. Na Figura 2, são apresentadas algumas das possíveis aplicações do NDVI, destacando-se o monitoramento de lavouras ao longo do ciclo de desenvolvimento, que acaba sendo mais uma ação de acompanhamento visual e de orientação de atividades de diagnóstico.

Outra aplicação é a detecção precoce de estresses hídricos e de deficiências nutricionais, principalmente de nitrogênio, tornando possível a recomendação de taxas variáveis de fertilizantes (Molin; Amaral; Colaço, 2015). Atualmente, existem inúmeros modelos de recomendação em taxa variável de N para as culturas do trigo, milho e algodão e que são praticados em escala comercial no Brasil. Além disso, as aplicações incluem a utilização de mapas de NDVI para a composição de “layers” de zonas de manejo, para a colheita estratificada de sementes ou para estimativas de produtividade de grãos desde os estádios iniciais de desenvolvimento da cultura.

Uma nova oportunidade do NDVI atualmente é a estimativa de sequestro de carbono pelas culturas ao longo do ciclo de desenvolvimento, além de estimativas de emergência das plantas em lavouras baseado no índice de vegetação MSAVI (Índice de vegetação ajustado ao solo modificado), outro índice que vem ganhando destaque e que possui capacidade de “identificar” plantas em estádios iniciais.




Figura 2. Aplicações do NDVI na agricultura. Fonte: André Luis Vian.

Também o uso de imagens de satélite que capturam os dados de NDVI, disponibilizadas diariamente, já é uma realidade para o monitoramento de estresse hídrico. Somado aos dados de temperatura de superfície (TS) também coletados por meio de satélite, é possível utilizá-los para avaliação da evolução de períodos de seca e sua severidade, em locais com informações meteorológicas escassas ou não acuradas (Cunha et al., 2017). Com isso, é possível aprimorar o manejo da irrigação, evitando desperdícios e aumentando a rentabilidade da lavoura.

De forma conjunta, o NDVI é utilizado como parâmetro para entender o desenvolvimento de outros índices de vegetação, como o LAI (índice de área foliar), do FAPAR (índice de radiação fotossinteticamente ativa interceptada) e do CWC (Conteúdo relativo de água no dossel vegetativo). Esses novos índices apresentam ótima relação com o NDVI e permitem avaliar informações específicas, além de simplesmente obter informações de clorofila e de biomassa.

Como forma de monitorar a ocorrência de pragas e doenças, o NDVI se mostra como uma alternativa para cultivos comumente acompanhados de forma manual. No cultivo da soja, o impacto gerado por uma doença, como a ferrugem asiática, pode ser crucial para uma

boa produtividade na safra, causando danos severos à lavoura, passíveis de observação por meio remoto. A redução de área fotossinteticamente ativa gera alteração no NDVI, sendo possível a criação de uma correlação entre o valor do NDVI calculado e a severidade da doença (Silva; Canteri; Moreira, 2024). Apesar disso, as mudanças aparentes no talhão somente são perceptíveis em um estágio muito avançado da doença/praga, não sendo recomendado o acompanhamento para controle por meio desta ferramenta.

Por fim, cabe citar a utilização do NDVI como forma de determinação da biomassa acumulada, com correlações já validadas em diversos cultivos, como trigo e cevada. Essa mensuração de biomassa da parte aérea é útil para estimativas de produtividade, gerando ganhos ao produtor por meio de um manejo mais localizado de acordo com a expectativa de rendimento, como no caso da adubação em taxa variável (Grohs, et al., 2011).

Limitações e cuidados com o uso de NDVI

Apesar de sua vasta aplicabilidade, a interpretação do NDVI requer cuidados para evitar diagnósticos imprecisos, pois diversos fatores podem influenciar seu valor. Uma das principais limitações quando usamos as plataformas satelitais é a sua sensibilidade a

condições meteorológicas, como a presença de nuvens e neblina, que podem afetar significativamente a precisão dos dados. Em dias nublados, a luz refletida pela vegetação pode ser dispersa, resultando em leituras distorcidas. Além disso, variações no ângulo solar ao longo do dia e das estações do ano podem alterar a forma como a luz interage com a vegetação, levando a mudanças nos valores do índice. Estudos em lavouras de soja mostraram que o NDVI tende a apresentar valores menores no início da manhã e final da tarde, quando a radiação solar incide com maior inclinação (Fontana *et al.*, 2019).

Outra limitação crucial é a saturação do NDVI em condições de alta densidade de biomassa (Fontana *et al.*, 2019). Em lavouras de soja com Índice de Área Foliar (IAF) superior a 5, o NDVI pode estabilizar-se em valores próximos a 0,9, tornando-se menos sensível a aumentos adicionais de biomassa. Nesses estágios mais avançados da cultura, outros índices, como o NDRE (Índice de Vegetação por Diferença Normalizada no Red Edge), podem complementar a análise.

Embora o NDVI contribua de forma positiva para o monitoramento da vegetação, suas limitações relacionadas às condições meteorológicas, ângulo solar, saturação em alta biomassa e defasagens temporais devem ser consideradas na interpretação dos dados. Nesse sentido, é indispensável o acompanhamento presencial das lavouras, de modo a entender as medições do NDVI de forma contextualizada ao local, podendo observar as características e possíveis causas dos valores indicados. A observação direta no campo permite validar os dados de NDVI, identificar padrões e compreender as reais condições das plantas, auxiliando em um diagnóstico mais preciso e na tomada de decisões mais eficientes.

Conclusões

É evidente que a importância do índice de NDVI na agricultura vem crescendo ao longo dos anos, fazendo-se presente em diversos manejos realizados durante o ciclo da cultura, como forma de embasamento para escolhas

mais assertivas para a lavoura. Traz consigo economia de insumos, tempo e mão de obra, elevando o padrão de produção para um conceito mais sustentável e diminuindo os impactos ambientais. Esse crescimento na utilização da ferramenta tende a se consolidar, evidenciando a necessidade de validação de dados e de parâmetros para mensuração do desenvolvimento da lavoura.

O emprego de tecnologias como o NDVI, associadas ao emprego de inteligência artificial para tabulação e comparação de dados, são o caminho para uma gestão ainda mais eficiente e autônoma da fazenda. Essas informações, associadas a ferramentas de machine learning que permitem à máquina tomar decisões, aumentam a precisão dos manejos empregados, eliminando erros subjetivos, trazendo um monitoramento mais eficiente e, conseqüentemente, uma prática agrícola mais sustentável.

Referências

- BARET, F. *et al.* Quantification of plant stress using remote sensing observations and crop models: the case of nitrogen management. *Journal of Experimental Botany*, Oxford, v. 58, n. 4, p. 869-880, 2007.
- CAMPBELL, J. B.; WYNNE, R. H. *Introduction to remote sensing*. 5. ed. Nova York: Guilford Press, 2011.
- COLOMINA, I.; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: a review. *ISPRS Journal of Photogrammetry and Remote Sensing*, Amsterdã, v. 92, p. 79-97, 2014.
- CUNHA, A. P. M. A. *et al.* Avaliação de indicador para o monitoramento dos impactos da seca em áreas de pastagens no semiárido do Brasil. *Revista Brasileira de Cartografia*, n. 69/1, 2017.
- EPIPHANIO, J. C. N.; FORMAGGIO, A. R.; RUDORFF, B. F. T.; MAIA, J. C. S.; GALVÃO, L. S. *Sensoriamento remoto aplicado ao monitoramento agrícola*. 2010.
- FONTANA, D. C. *et al.* NDVI e alguns fatores de variabilidade. *Anais... XIX Simpósio Brasileiro de Sensoriamento Remoto*, 2019.
- GROHS, D. S. *et al.* Validação de modelo para predição do potencial produtivo de trigo com sensor óptico ativo. *Pesquisa Agropecuária Brasileira*, v. 46, n. 4, 2011.
- HANK, T. B.; BERGER, K.; BACH, B.; CLEVERS, J. G. P. W.; GITELSON, A.; ZARCO-TEJADA, P.; MAUSER, W. Spaceborne Imaging Spectroscopy for Sustainable Agriculture: Contributions and Challenges. *Surveys in Geophysics* (2019), V. 40, P. 515 – 551. <https://doi.org/10.1007/s10712-018-9492-0>.
- HUANG, S. *et al.* A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. *Journal of Forestry Research*, v. 32, n. 1, p. 1–6, 2020.

JACKSON, R. D.; HUETE, A. R. Interpreting vegetation indices. Preventive Veterinary Medicine, v. 11, n. 3-4, p. 185–200, dez. 1991.

JACÓBSEN, Lizandro Oliveira; FONTANA, Denise Cybis; SHIMABUKURO, Yosio Edemir. Efeitos associados a El Niño e La Niña na vegetação do Estado do Rio Grande do Sul, observados através do NDVI/NOAA. Revista brasileira de meteorologia. Brasília. Vol. 19, n. 2 (2004), p. 129-140, 2004.

JENSEN, J. R. Remote sensing of the environment: an earth resource perspective. 2. ed. Upper Saddle River: Prentice Hall, 2015.

KRIEGLER, F. J. et al. Preprocessing transformations and their effects on multispectral recognition. In: INTERNATIONAL SYMPOSIUM ON REMOTE SENSING OF ENVIRONMENT, 6., 1969, Ann Arbor. Anais... Ann Arbor: Environmental Research Institute of Michigan, 1969. p. 97-131.

LILLESAND, T. M. et al. Remote sensing and image interpretation. 7. ed. Hoboken: Wiley, 2015.

MOLIN, J. P.; AMARAL, L. R.; COLAÇO, A. F. Agricultura de precisão. São Paulo: Oficina de Textos, 2015.

SILVA, R. G.; FREITAS, L. M.; SANTANA, D. J. NDVI aplicado ao manejo sustentável de pastagens em ILP. Agricultura Sustentável, v. 15, n. 3, p. 112-126, 2019.

SILVA, A. L.; CANTERI, M. G.; MOREIRA, G. G. Comparação de imagens aéreas com câmeras NIR usando veículos não tripulados (VANTs) para estimativa de severidade e desfolha de *Phakopsora pachyrhizi* na cultura da soja. Summa Phytopathologica, v. 50, 2024.

ZHANG, C.; KOVACS, J. M. The application of small unmanned aerial systems for precision agriculture: a review. Precision Agriculture, Berlim, v. 13, p. 693-712, 2012.