

UNIVERSIDADE FEDERAL DE PELOTAS
Faculdade de Agronomia Eliseu Maciel
Programa de Pós-Graduação em Manejo e Conservação do Solo e da Água



Dissertação

**Índice de vegetação EVI2 e atributos físico e químicos do solo relacionados a
variabilidade espacial da produtividade da soja**

Jones Ortiz de Moraes

Pelotas, 2026

Jones Ortiz de Moraes

**Índice de vegetação EVI2 e atributos físico e químicos do solo relacionados a
variabilidade espacial da produtividade da soja**

Dissertação apresentada ao Programa de Pós
Graduação em Manejo e Conservação do Solo e
da Água da Faculdade de Agronomia Eliseu
Maciel da Universidade Federal de Pelotas,
como requisito parcial à obtenção do título de
Mestre em Ciências.

Orientador: Dr. Filipe Selau Carlos
Coorientador: Dr. Rogério Oliveira de Sousa

Pelotas, 2026

Universidade Federal de Pelotas / Sistema de Bibliotecas
Catalogação da Publicação

M828i Moraes, Jones Ortiz de

Índice de vegetação EVI2 e atributos físico e químicos do solo relacionados a variabilidade espacial da produtividade da soja [recurso eletrônico] / Jones Ortiz de Moraes ; Filipe Selau Carlos, orientador ; Rogerio Oliveira de Sousa, coorientador. — Pelotas, 2026.
47 f. : il.

Dissertação (Mestrado) — Programa de Pós-Graduação em Manejo e Conservação do Solo e da Água, Faculdade de Agronomia Eliseu Maciel, Universidade Federal de Pelotas, 2026.

1. Agricultura de precisão. 2. Sentinel-2. 3. Sensoriamento remoto. 4. Grade regular. 5. EVI2. I. Carlos, Filipe Selau, orient. II. Sousa, Rogerio Oliveira de, coorient. III. Título.

CDD 630.28

Agradecimentos

À minha esposa Bruna Ribeiro, que esteve sempre ao meu lado incentivando e colaborando em todas as etapas ao longo dessa jornada. Sua atenção e compreensão tornaram essa jornada mais leve e possível.

Aos meus pais João José Alvarenga de Moraes e Ana Maria Ortiz de Moraes, deixo um agradecimento especial, sempre me incentivaram a estudar e fizeram de tudo para que esse momento fosse possível.

Ao meu orientador Prof. Dr. Filipe Selau Carlos, pela oportunidade concedida e os ensinamentos compartilhados.

Ao meu coorientador Prof. Dr. Rogério Oliveira de Sousa pelo suporte ao longo dessa jornada.

Ao Prof. Dr. Rodrigo Rizzi, pelo suporte oferecido para o desenvolvimento desse trabalho, disponibilizando seu tempo para esclarecer dúvidas e dar sugestões. Sua colaboração e suas críticas foram fundamentais para o desenvolvimento desse estudo.

Agradeço também, ao meu amigo Marcelo Santin, por disponibilizar a sua propriedade para que o estudo fosse realizado e por todo apoio ao longo dessa jornada.

Agradeço aos colegas do PPG MACSA, os quais estivemos juntos ao longo dessa etapa, compartilhando momentos de alegrias e aflições, trocando conhecimentos importantes para o nosso crescimento.

Ao PPG MACSA pelas oportunidades de aperfeiçoamento profissional oferecidas ao longo dessa jornada. Agradeço também, a Coordenação de Aperfeiçoamento do Pessoal de Educação Superior (CAPES), pela concessão da bolsa de estudo.

Resumo

MORAES, Jones O. **Índice de vegetação EVI2 e atributos físico e químicos do solo relacionados a variabilidade espacial da produtividade da soja**. Orientador: Filipe Selau Carlos. 2026, 47p. Dissertação (Mestrado em Manejo e Conservação do Solo e da Água) - Faculdade de Agronomia Eliseu Maciel, Universidade Federal de Pelotas, 2026.

A soja (*Glycine max* (L.) Merrill.), ocupa posição estratégica na agricultura brasileira e mundial, com projeção de aumento da participação do Brasil nas exportações globais, o que intensifica a necessidade de manejo eficiente em ambientes edafoclimáticos diversos, nos quais a heterogeneidade espacial do talhão amplia a variabilidade de produtividade e demanda abordagens orientadas por dados. Nesse contexto, este estudo avaliou, em lavoura comercial de cerca de 11 ha em Canguçu-RS, a capacidade de atributos químicos do solo e do índice de vegetação Enhanced Vegetation Index 2 (EVI2) em representar a variabilidade espacial da produtividade da soja. Foram amostrados 55 pontos georreferenciados em grade regular, com coleta de 8 subamostras de solo na camada de 0,0–0,20 m e determinação de produtividade por colheita manual em parcela de 5 m, com correção de umidade para 13%. O EVI2 foi obtido de imagens Sentinel-2 (nível 2A; 10 m) em diferentes datas do ciclo da cultura. Foi aplicada estatística descritiva, correlação de Spearman, regressão linear simples e Krigagem ordinária para mapeamento. As correlações entre atributos químicos do solo e produtividade foram, em geral, fracas e inconsistentes ($|\rho| < 0,30$), sugerindo baixa capacidade explicativa de atributos isolados na escala do talhão. Em contraste, o EVI2 apresentou associação positiva consistente com a produtividade, $\rho = 0,71$ aos 108 dias após a semeadura (DAS). Os modelos de regressão indicaram capacidade de explicação em torno de um terço a cerca de 40% da variabilidade da produtividade nas janelas fenológicas mais informativas, com $R^2 = 0,413$ aos 108 DAS, reforçando o potencial do EVI2 de representar de forma robusta a variabilidade produtiva no talhão,

Palavras Chave: Agricultura de precisão; Sentinel-2; sensoriamento remoto; grade regular; EVI2.

Abstract

MORAES, Jones O. **EVI2 vegetation index and soil physical and chemical attributes related to the spatial variability of soybean yield**. Advisor: Filipe Selau Carlos. 2026, 47p. Dissertation (Master's Degree in Soil and Water Management and Conservation) - Eliseu Maciel School of Agronomy, Federal University of Pelotas, 2026.

Soybean (*Glycine max* (L.) Merrill.) holds a strategic position in both Brazilian and global agriculture, with projections indicating an increased share of Brazil in global exports, which intensifies the need for efficient management across diverse edaphoclimatic environments, where within-field spatial heterogeneity amplifies yield variability and calls for data-driven approaches. In this context, this study evaluated, in a commercial soybean field of approximately 11 ha in Canguçu, Rio Grande do Sul (RS), Brazil, the ability of soil chemical attributes and the vegetation index Enhanced Vegetation Index 2 (EVI2) to represent the spatial variability of soybean yield. Fifty-five georeferenced sampling points were established on a regular grid, with soil sampling based on eight subsamples in the 0.0–0.20 m layer and yield determined by manual harvest from 5 m plots, with grain moisture corrected to 13%. EVI2 values were derived from Sentinel-2 imagery (Level-2A; 10 m) acquired on different dates throughout the crop cycle. Descriptive statistics, Spearman's correlation, simple linear regression, and ordinary kriging were applied for spatial analysis and mapping. Correlations between soil chemical attributes and yield were generally weak and inconsistent ($|r| < 0.30$), indicating limited explanatory power of isolated attributes at the field scale. In contrast, EVI2 showed a consistent positive association with yield, reaching $r = 0.71$ at 108 days after sowing. Regression models explained roughly one third to about 40% of yield variability in the most informative phenological windows, with $R^2 = 0.413$ at 108 days after sowing, reinforcing the potential of EVI2 to robustly represent within-field yield variability.

Keywords: Precision agriculture; Sentinel-2; remote sensing; regular grid; EVI2.

Lista de Figuras

Figura 1	Localização da área de estudo	20
Figura 2	Grade amostral	21
Figura 3	Amostras de solo coletadas	22
Figura 4	Pesagem de amostras	23
Figura 5	Mapa de distribuição de produtividade	27
Figura 6	Distribuição espacial de atributos químicos do solo na área da lavoura	30
Figura 7	Correlação de Spearman entre atributos físico e químicos do solo e produtividade da soja	31
Figura 8	Variação espacial do EVI2 ao longo do ciclo de desenvolvimento da cultura da soja	33
Figura 9	Correlação de Spearman entre EVI2 e produtividade da soja	35
Figura 10	Gráfico de dispersão (produtividade x EVI2)	37

Lista de Tabelas

Tabela 1 Data de aquisição das imagens.....	24
Tabela 2 Estatística descritiva de atributos físico e químicos do solo na camada de 0,0 – 0,20m	28

Sumário

1 Introdução	9
2 Revisão de Literatura	12
2.1 Agricultura de Precisão e variabilidade espacial na cultura da soja	12
2.1.1 Variabilidade espacial intra-talhão em sistemas de produção de soja	12
2.1.2 Benefícios potenciais da Agricultura de Precisão na eficiência de uso de insumos	13
2.2 Zonas de Manejo	14
2.3 Amostragem de solo em grade regular e sua aplicação em lavouras comerciais .	15
2.3.1 Princípios da amostragem em grade (<i>grid sampling</i>).....	15
2.3.2 Densidade amostral, escalas espaciais e implicações para o mapeamento da fertilidade.....	16
2.4 Sensoriamento remoto e índices de vegetação aplicados à cultura da soja.....	17
2.4.1 Fundamentos de sensoriamento remoto em agricultura.....	17
2.4.2 Índices de vegetação NDVI, EVI e EVI2.....	18
3 Metodologia.....	20
3.1 Caracterização da área.....	20
3.2 Delineamento amostral e coleta de dados	21
3.2.1 Amostragem de solo em grade regular.....	21
3.2.2 Amostragem de solo	22
3.2.3 Determinação da produtividade da soja	23
3.2.4 Obtenção e processamento de imagens EVI2 do sensor MSI/Sentinel-2.....	23
3.3 Organização e tratamento preliminar dos dados.....	24
3.4 Análise estatísticas e geoestatísticas.....	25
3.4.1 Correlação entre atributos do solo e produtividade.....	25
3.4.2 Correlação e regressão entre EVI2 e produtividade	25
3.4.3 Interpolação espacial e elaboração de mapas temáticos	26
3.4 Softwares e ferramentas utilizadas	26
4 Resultados e Discussões	27
4.1 Produtividade da cultura da soja	27
4.2 Variabilidade dos atributos químicos do solo	28
4.3 Relação entre atributos físico e químicos do solo e produtividade da soja	31
4.4 Variação espacial do EVI2	32
4.5 Relação entre produtividade e EVI2.....	34
Conclusões	39
Referências.....	40

1 Introdução

A cultura da soja (*Glycine max* (L.) Merrill.), ocupa posição estratégica na agricultura mundial e, em particular, no contexto brasileiro. Relatórios recentes indicam que o Brasil se consolidou como produtor e exportador mundial de soja, com uma tendência de aumento da participação do país nas exportações globais que deve chegar a 60,6 % até 2032/2033 (Valdes; Gillespie; Dohlman, 2023). Estudo realizado por Tolo *et al.* (2021), evidencia que a soja contribui diretamente para receitas municipais e estaduais, influenciando indicadores econômicos, sociais e ambientais em importantes regiões produtoras de soja no Brasil.

A expansão da soja em ambientes edafoclimáticos diversos impõem desafios de manejo associados à heterogeneidade espacial de um talhão. Pois a interação complexa entre fatores ambientais e atributos do solo aumenta a variabilidade espacial da produtividade. Nesse cenário, a Agricultura de Precisão (AP) tem sido amplamente discutida como abordagem de manejo orientada por dados, que busca monitorar e quantificar a variabilidade espacial e temporal da lavoura para otimizar o uso de insumos, aumentar a eficiência produtiva e reduzir impactos ambientais (Getahun *et al.*, 2024; Mishra *et al.*, 2025; Saha *et al.*, 2025).

Dentro do contexto da AP, estudos mostram que a delimitação de zonas de manejo, buscando áreas que apresentam uma resposta mais homogênea da cultura quanto ao uso de insumos podendo ser realizado com base em atributos de solo e/ou paisagem, dados de produtividade e combinações de múltiplas camadas de informação, utilizando diferentes métodos de agrupamento e análise multivariada (Ali *et al.*, 2022; Speranza *et al.*, 2023).

Historicamente, a delimitação dessas zonas de manejo baseou-se fortemente em amostragem de solo em grade regular, com recomendações de no mínimo uma amostra por hectare, a depender da região, seguida de técnicas geoestatísticas e análise multivariada, para mapear a variabilidade de fertilidade, a possível presença de pragas, áreas de solo compactados e etc. (Cherubin *et al.*, 2015). No entanto, esse tipo de abordagem gera custos elevados, tornando-se um entrave importante para pequenos e médios produtores, que operam com margens mais estreitas do ponto de vista financeiro e menor acesso a serviços especializados de AP, apontando a necessidade de modelos de adoção e protocolos simplificados (United Nations Development Programme, 2021).

Em paralelo, o avanço nas últimas décadas de sensores remotos e plataformas de processamento de imagens trouxe para o centro do debate o uso de [Índices de Vegetação (IVs)]. Mais recentemente, o *Enhanced Vegetation Index 2* (EVI2), proposto como uma versão de duas bandas do EVI, mantendo as propriedades de ajustamento ao solo e linearização sem a necessidade de banda azul, ganhou relevância em aplicações com sensores que não dispõem de todas as bandas do EVI original (Jiang *et al.*, 2008).

Estudos com soja e outras culturas têm demonstrado que os IVs podem se correlacionar com a biomassa, a absorção de nutrientes e, em determinados estádios e condições, com a produtividade, sendo úteis no auxílio ao diagnóstico nutricional, monitoramento de estresses, previsão de produtividade e delimitação de zonas homogêneas da cultura (Bolton; Friedl, 2013.; Damian *et al.*, 2020.; Speranza *et al.*, 2023). Embora a relação entre IVs e a produtividade das culturas seja sensível ao estágio fenológico e às condições de clima e manejo, a análise de séries temporais de IVs ao longo do ciclo de crescimento e desenvolvimento da cultura pode melhorar significativamente a capacidade de predição de produtividade, possibilitando a identificação de zonas com maior ou menor potencial produtivo (Farias *et al.*, 2023).

A evolução das tecnologias de AP e o aumento na capacidade computacional em processamento e análise de dados nas últimas décadas, facilitou a integração de múltiplas camadas de dados, potencializando a redução do desperdício de insumos e a mitigação de impactos ambientais (Melo; Cunha; Amaral, 2025). Entretanto, a evolução tecnológica presente no avanço da AP, ainda são reportadas em sua maioria, em contextos de maior escala produtiva e infraestruturas tecnológicas mais robustas, com menor ênfase em protocolos adaptados a pequenos produtores com talhões de pequeno e médio porte (Onyango *et al.*, 2021).

Diante desse cenário, torna-se necessário investigar, em condições reais de lavoura comercial e em escala compatível com propriedades de pequeno porte, quais fontes de informação são mais eficientes para caracterizar a heterogeneidade intra-talhão da produtividade e, assim, subsidiar decisões no contexto da AP que visão auxilia na tomada de decisão, reduzindo custos e aumentando o potencial produtivo e reduzindo danos ambientais.

Em muitas áreas, a amostragem de solo em grade regular permanece como estratégia central de diagnóstico da variabilidade, porém envolve custos operacionais e analíticos elevados e, frequentemente, limita a adoção de densidades amostrais

mais altas. Nesse sentido, avaliar em que medida os atributos químicos do solo, medidos pontualmente, se associam à produtividade da soja é essencial para conferir consistência agrônoma às recomendações de manejo e, quando necessário, revisar protocolos amostrais e critérios de intervenção.

Paralelamente, a crescente disponibilidade de índices de vegetação derivados de imagens de satélite, como os obtidos pelo sensor MSI a bordo da plataforma Sentinel-2, amplia as possibilidades de monitoramento da cultura com alta cobertura espacial e frequência temporal. Em particular, o EVI2 pode capturar variações no vigor e no desenvolvimento do dossel ao longo do ciclo, oferecendo um diagnóstico indireto, baseado na resposta espectral da soja, com potencial para complementar ou otimizar o diagnóstico do talhão e reduzir custos de monitoramento.

Portanto, as hipóteses deste estudo são: a) Os atributos químicos do solo apresentam variabilidade espacial que se correlacionam com a produtividade da soja em lavoura de pequeno porte, sendo capaz de explicar adequadamente a variabilidade da produtividade da cultura ; b) O índice de vegetação EVI2 avaliado, ao longo do ciclo de desenvolvimento da soja, apresenta associação com a produtividade da cultura e é capaz de explicar parcela relevante da variabilidade espacial da produtividade, configurando-se como uma ferramenta para representar a heterogeneidade produtiva da lavoura.

Assim, o estudo proposto ganha relevância científica e agrônoma, ao avaliar em uma lavoura comercial de soja de pequeno porte, a capacidade de atributos de solo amostrados em grade regular e do EVI2, derivado de imagens MSI/Sentinel-2, em representar a variabilidade espacial da produtividade, possibilitando diagnóstico da variabilidade e apoio ao manejo em lavouras comerciais de pequeno porte. Já os objetos específicos foram: a) Caracterizar a variabilidade espacial da produtividade da soja no talhão, por meio de estatística descritiva e krigagem dos dados de produtividade; b) Descrever e investigar a variabilidade dos atributos químicos do solo e produtividade por meios de análises de correlação; c) Quantificar a relação entre EVI2 e produtividade da soja, por meio de correlação e modelos de regressão linear simples.; d) Discutir o potencial de uso do EVI2 como ferramenta operacional no monitoramento e caracterização do potencial produtivo em área de soja, visando reduzir a dependência de alta densidade das grades amostrais tradicionalmente utilizadas.

2 Revisão de Literatura

2.1 Agricultura de Precisão e variabilidade espacial na cultura da soja

A Agricultura de Precisão (AP) pode ser entendida como um sistema de manejo agrícola orientado por informações, que busca caracterizar a variabilidade espacial e temporal de uma determinada área, com o objetivo de otimizar o uso de insumos, aumentar o retorno econômico e reduzir impactos ambientais. Em contraste com o manejo tradicional, baseado na aplicação uniforme de insumos em grandes áreas, a AP parte do pressuposto de que o solo e a cultura não são homogêneos no espaço, e que decisões de manejo podem e devem ser diferenciadas em subáreas com características distintas. (Molin *et al.*, 2020).

Bernardi *et al.* (2018), destacam que a AP deve ser compreendida mais como um conceito de gestão do que como um conjunto fechado de tecnologias, envolvendo etapas de coleta de dados, processamento e análise e, por fim, a tomada de decisão sítio-específica. Molin *et al.* (2020), ao discutir o contexto da “agricultura digital” ou “Agricultura 4.0”, reforça que a AP está cada vez mais inserida em um ecossistema tecnológico que inclui automação, telemetria, Internet das Coisas (IoT) e plataformas de armazenamento e análise de dados em nuvem.

Estudo recente aponta que a AP pode contribuir para aumentar a eficiência no uso de recursos, permitindo maior produtividade com a mesma quantidade de insumos ou manutenção da produtividade com redução de doses, reforçando seu potencial alinhamento com a sustentabilidade, no entanto, tais benefícios não são garantidos e podem variar de acordo com o contexto da propriedade agrícola (Ruder *et al.*, 2026).

Em contextos de agricultores com propriedades de menor escala produtiva, estudos também mostram que a adoção da AP, ainda que com tecnologias relativamente simples, pode melhorar a eficiência no uso de fertilizantes e água, mesmo sem aumento significativo do volume de insumos utilizados (Onyango *et al.*, 2021).

2.1.1 Variabilidade espacial intra-talhão em sistemas de produção de soja

A variabilidade espacial intra-talhão resulta da interação entre fatores de formação e uso do solo, práticas de manejo e condições meteorológicas, entre outros. Neto *et al.* (2020), avaliando um Latossolo cultivado com soja, observaram que

atributos de fertilidade (pH, P, K, matéria orgânica) apresentaram dependência espacial moderada a forte e que a produtividade da soja respondia de forma diferenciada a essa variabilidade, reforçando a necessidade de estratégias de manejo que considerem a heterogeneidade do solo.

Trabalhos com séries históricas de produtividade reforçam que essa variabilidade não é apenas espacial, mas também espaço temporal. Maltauro *et al.* (2025) ao analisarem dez safras consecutivas de soja em uma área comercial no Paraná, mostraram que existem regiões da lavoura com padrões de produtividade sistematicamente superiores ou inferiores, associadas a características de solo e relevo, e que essas zonas mantêm certa estabilidade ao longo dos anos, ainda que influenciadas por variações climáticas sazonais.

No contexto brasileiro, essa variabilidade assume relevância adicional devido à diversidade de ambientes de cultivo como o Cerrado, Sul e Matopiba, onde o clima, tipo de solo e relevo dentre outros fatores influenciam na heterogeneidade do solo. Estudos sobre AP no Brasil destacam que o reconhecimento e o manejo da variabilidade intra-talhão são centrais para reduzir perdas por superdosagem de insumos em áreas de baixo potencial e subdosagem em áreas de maior exigência, impactando diretamente a rentabilidade e a sustentabilidade do sistema produtivo (Bernardi *et al.*, 2018).; Molin *et al.*, 2020).

2.1.2 Benefícios potenciais da Agricultura de Precisão na eficiência de uso de insumos

Bernardi *et al.* (2018) mostraram que a consideração da variabilidade espacial na recomendação de adubação pode resultar em maior retorno econômico por área, especialmente quando combinações de dados de solo e produtividade da cultura são utilizadas para definir zonas de manejo e estratégias de taxa variável de aplicação de fertilizantes e semeadura por exemplo. Revisões mais amplas sobre tecnologias de AP para manejo sítio-específico de nutrientes reforçam que a adoção de amostragem estratégica, sensoriamento remoto e recomendação diferenciada pode reduzir perdas de nutrientes por lixiviação ou volatilização, ao mesmo tempo em que mantém ou aumenta a produtividade, alinhando-se a metas de agricultura sustentável (Molin; Tavares, 2019.; Vullaganti, *et al.*, 2025).

Estudos recentes sobre AP e sustentabilidade enfatizam ainda que, além de ganhos econômicos, há evidência de benefícios ambientais associados à aplicação

mais precisa de insumos, como menor uso de fertilizantes nitrogenados por unidade de produção, redução de emissões de gases de efeito estufa e mitigação de riscos de contaminação de água e solo (United Nations Development Programme, 2021.; Ruder *et al.*, 2026).

Para pequenos e médios produtores, Onyango *et al.* (2021) mostraram que práticas mais precisas, como adubação localizada, uso de mapas simples de variabilidade, fertilização orientada por diagnósticos espaciais mesmo que com baixa tecnologia, podem melhorar a relação custo/benefício e aumentar a resiliência econômica.

2.2 Zonas de Manejo

A literatura apresenta diversas abordagens para o delineamento de zonas de manejo (MZs), que podem ser agrupadas, de forma geral, em três grandes categorias: baseadas em solo e relevo; baseadas em dados de produtividade; derivadas da integração de múltiplas fontes. Estudos pioneiros em MZs utilizaram principalmente atributos de solo e características de paisagem para agrupar subáreas com potencial produtivo semelhante. Nawar *et al.* (2017) discutem extensivamente abordagens em que mapas de pH, matéria orgânica, fósforo, potássio, textura, condutividade elétrica aparente (ECa) e variáveis de relevo são usados como base para algoritmos de agrupamento (k-means, fuzzy c-means, classificação hierárquica), gerando zonas que refletem a estrutura espacial de propriedades edáficas de maior estabilidade temporal.

Em trabalhos mais recentes em sistemas de grãos no Brasil, atributos de solo e condutividade elétrica têm sido utilizados como base primária para criação de zonas de manejo, com validação posterior por produtividade de culturas como milho e soja (Guimarães; Cunha; Hurtado, 2024).

Outra linha de abordagem utiliza mapas de produtividade, geralmente obtidos por colhedoras equipadas com sensores de fluxo de massa e *Global Positioning System* (GPS), como principal fonte de informação. A ideia é que a produtividade reflita o efeito de múltiplos fatores (solo, clima, manejo, pragas, doenças) e que padrões espaciais recorrentes de produtividade alto ou baixo indicam zonas com respostas distintas (Nawar; Mulla; Mouazen, 2017).

Trabalhos como os de Bottega *et al.* (2017) com a cultura da soja no Brasil, empregaram séries de mapas de produtividade para avaliar a estabilidade temporal de zonas de manejo, mostrando que algumas permanecem relativamente constantes

em termos de produtividade relativa, mesmo sob condições climáticas variáveis, o que reforça sua utilidade como unidades de manejo.

Uma tendência consolidada é a utilização de abordagens integradas, em que diferentes camadas de dados (solo, produtividade, sensores proximais e remotos) são combinadas por meio de técnicas multivariadas, como análise de componentes principais (PCA), análise fatorial, análise de agrupamento (k-means, fuzzy c-means, ISODATA) e, mais recentemente, métodos de aprendizado de máquina, para delinear MZs mais robustas (Beneduzzi *et al.*, 2022).

No contexto brasileiro, Speranza *et al.* (2023) propuseram uma metodologia para delinear MZs com diferentes potenciais de produtividade em sistemas soja/milho e soja/algodão, integrando dados de amostragem de solo, sensores proximais e sensores orbitais, evidenciando que a combinação de múltiplas fontes permitiu identificar zonas com diferenças significativas de produtividade e características de solo.

Mais recentemente, têm surgido estudos nos quais índices de vegetação derivados de sensoriamento remoto assumem papel importante no delineamento de zonas de manejo, englobando a utilização integrada de imagens de satélite, condutividade elétrica aparente, amostragem de solo e modelos de machine learning para geração de zonas de manejo, com foco no melhor aproveitamento no uso de insumos e mitigação de efeitos ambientais (Romano *et al.*, 2025.; Jovanović *et al.*, 2025.; Dogar *et al.*, 2025).

2.3 Amostragem de solo em grade regular e sua aplicação em lavouras comerciais

2.3.1 Princípios da amostragem em grade (*grid sampling*)

A amostragem de solo em grade regular (*grid sampling*) é uma das estratégias mais tradicionais da Agricultura de Precisão para caracterizar a variabilidade espacial dos atributos químicos do solo em nível de talhão (Mallarino; Wittry, 2004.; Lawrence *et al.*, 2020). Em termos gerais, o método consiste em subdividir a área em células de tamanho pré-definido e coletar uma amostra (geralmente composta por vários subpontos) em cada célula, com georreferenciamento dos pontos amostrais. Posteriormente essas amostras são analisadas e os resultados interpolados, com uso frequente de métodos geoestatísticos como a krigagem, para gerar mapas contínuos de fertilidade e subsidiar o manejo localizado (Nanni *et al.*, 2011.; Valente *et al.*, 2024).

No Brasil, revisões sobre a trajetória da Agricultura de Precisão indicam que os primeiros esforços foram amplamente baseados em amostragem de solo georreferenciada em grade, seguida de interpolação geoestatística, para mapear atributos químicos e subsidiar recomendações de calcário e fertilizantes em taxa variável (Cherubin *et al.*, 2022). Em muitos estudos de variabilidade espacial de fertilidade no Cerrado e em outras regiões, a grade regular é o desenho amostral de referência, usado tanto para caracterização descritiva quanto para ajuste de modelos geoestatísticos, variando o número de amostras por hectare de acordo com a região (Cherubin *et al.*, 2015.; Carneiro *et al.*, 2016).

2.3.2 Densidade amostral, escalas espaciais e implicações para o mapeamento da fertilidade

A escolha da grade amostral é influenciada por diferentes culturas e contextos e influencia diretamente na qualidade dos mapas. Nanni *et al.* (2011), avaliaram diferentes tamanhos de grade na recomendação em taxa variável e discutiram um “tamanho ótimo” de grid para aplicações de calcário e fertilizantes, destacando que grades muito espaçadas (baixa densidade) podem não captar adequadamente a variabilidade, enquanto grades excessivamente densas elevam o custo sem ganhos proporcionais de acurácia.

Na cultura da soja, Guedes *et al.* (2016) compararam mapas de produtividade gerados a partir de diferentes grades de amostragem e configurações otimizadas versus regular, utilizando geoestatística. Os autores mostraram que grades mais densas permitiram melhor descrição da estrutura espacial da produtividade, mas também demonstraram que é possível otimizar o posicionamento dos pontos para reduzir o número de amostras mantendo a qualidade dos mapas (Melo; Cunha; Amaral, 2025).

Revisões recentes sobre AP no Brasil destacam que, entre os anos 2000 e 2010, uma linha importante de pesquisa buscou justamente identificar qual o tamanho ótimo de grade para diferentes situações, considerando a relação entre custo de amostragem e qualidade dos mapas. Esses trabalhos apontam que a densidade amostral ideal depende do atributo avaliado, por exemplo, P e K, podem variar mais intensamente que pH ou MO, da heterogeneidade do ambiente e do nível de precisão desejado nas recomendações de taxa variável (Cherubin *et al.*, 2022).

Gonçalves *et al.* (2020) compararam diferentes métodos de amostragem avaliando não apenas as diferenças nas recomendações de insumos, mas também impactos econômicos e ambientais, mostrando que abordagens baseadas em zonas de manejo e condutividade elétrica podem reduzir tanto o número de amostras quanto o volume de corretivos, sem perda de acurácia nas recomendações

Mais recentemente, Valente *et al.* (2024) compararam a acurácia de diferentes técnicas de amostragem de solo (grade de alta densidade, grade de baixa densidade, amostragem em células, amostragem por zonas de manejo e amostragem convencional) em áreas de produção no Brasil, utilizando o erro quadrático médio (RMSE) como métrica. Os autores concluíram que amostragem em células e por zonas de manejo apresentaram menor erro, seguidas pelas grades de alta densidade; já grades de baixa densidade apresentaram erro maior, indicando que a redução indiscriminada do número de pontos em grades amostrais tradicionais pode comprometer a qualidade dos mapas.

No Brasil, revisões sobre AP indicam que o uso de grade amostral de solo como primeira entrada foi importante para disseminar a tecnologia, mas apontam uma tendência recente de migração para modelos mais integrados, em que se utiliza uma campanha inicial de amostragem relativamente densa e, depois, estratégias de amostragem dirigida por zonas, mapas de produtividade e oriundos de sensoriamento remoto para atualizar diagnósticos com menor custo (Cherubin *et al.*, 2022).

2.4 Sensoriamento remoto e índices de vegetação aplicados à cultura da soja

2.4.1 Fundamentos de sensoriamento remoto em agricultura

O sensoriamento remoto no monitoramento da atividade agrícola baseia-se na medida da radiação refletida ou emitida pela superfície (solo e dossel) em direção do sensor em diferentes comprimentos de onda, por sensores instalados em satélites, aeronaves, VANTs (drones) ou plataformas terrestres. A partir dessas medidas, é possível derivar variáveis biofísicas (como índice de área foliar, biomassa, teor de clorofila, conteúdo de água) e indicadores de estresse, para o monitoramento de culturas como a soja (Radočaj *et al.*, 2023).

Revisões recentes enfatizam que os dados de sensoriamento remoto têm sido incorporados a diversas etapas do manejo: diagnóstico nutricional, detecção de estresses bióticos e abióticos, estimativa de produtividade e delineamento de zonas de manejo (Radočaj *et al.*, 2023). Prince Czarnecki *et al.* (2025), ao revisarem o uso

de sensoriamento remoto aplicado à soja, mostram que houve um avanço expressivo tanto na disponibilidade de sensores (desde os da série Landsat e MODIS a MSI/Sentinel-2, PlanetScope e câmeras multiespectrais embarcadas em VANTs) quanto nos métodos de análise.

O aumento no número de plataformas e sensores possibilitou uma maior cobertura temporal, no entanto, a questão da resolução temporal é um dos problemas descrito por Xue; Su. (2017), sobre o uso do sensoriamento remoto orbital tendo em vista que em sensores passivos a presença de nuvens afeta a qualidade da imagem, dificultando a interpretação correta sobre o alvo.

Entre as plataformas orbitais com ampla adoção em estudos agrônômicos, destaca-se a missão Sentinel-2, cujo sensor Multispectral Instrument (MSI) coleta dados em 13 bandas espectrais, com resoluções espaciais de 10 m, 20 m e 60 m, permitindo monitoramento multitemporal do dossel e suporte a análises intra-talhão (Gascon *et al.*, 2017).

Para análises voltadas à comparabilidade radiométrica entre datas e à derivação de índices de vegetação, é recorrente o uso do produto Sentinel-2 MSI Nível 2A (L2A), que fornece reflectância de superfície ortorretificada (*Bottom-Of-Atmosphere – BOA*), a geração do L2A é baseada no processamento de correção atmosférica e classificação de cena realizado pelo processador Sen2Cor, que converte produtos L1C (TOA) em BOA (Gascon *et al.*, 2017).

2.4.2 Índices de vegetação NDVI, EVI e EVI2

Os índices de vegetação (IVs) são combinações matemáticas de bandas espectrais, em geral nas regiões do vermelho, infravermelho próximo (IVP) e, em alguns casos azul, verde ou borda vermelha. Eles têm como objetivo realçar a contribuição da vegetação viva e reduzir o efeito de fatores de fundo (solo, sombra, pequenas variações de iluminação e visada e de interferência atmosférica), proporcionando métricas padronizadas de vigor do dossel (Radočaj *et al.*, 2023).

Dentre os diversos IVs utilizados na agricultura de precisão, o de maior destaque ao longo do tempo é o *Normalized Difference Vegetation Index* (NDVI) (Radočaj *et al.*, 2023). O NDVI, embora amplamente utilizado, apresenta saturação em dosséis muito densos e sensibilidade a variações de fundo do solo em coberturas vegetais esparsas (Yan *et al.*, 2025).

Para contornar parte dessas limitações, foi proposto o EVI (*Enhanced Vegetation Index*), que introduz fatores de ganho e correção atmosférica e um termo de ajuste de solo, de modo a melhorar a sensibilidade em altas biomassas e reduzir a influência de aerossóis presentes na atmosfera. Posteriormente em 2008, foi proposto o EVI2 que utiliza apenas as bandas do vermelho e infra-vermelho próximo, preservando o ajuste de solo e a maior linearidade em relação a variáveis biofísicas (Jiang *et al.*, 2008).

O EVI2 é expresso pela seguinte fórmula:

$$(1) \text{ EVI2} = 2,5 \times \frac{(\rho\text{NIR} - \rho\text{Red})}{(\rho\text{NIR} + 2,4 \times \rho\text{Red} + 1)}$$

Em que ρNIR e ρRed são as reflectâncias no infravermelho próximo e no vermelho respectivamente, o coeficiente 2,5 atua como fator de ganho, amplificando a resposta do índice às variações no contraste e aumentando sua sensibilidade ao vigor do dossel, em quanto, o termo 2,4 pondera a contribuição do vermelho no denominador, contribuindo para atenuar efeitos de fundo do solo e reduzir a saturação em dosséis mais densos (Jiang *et al.*, 2008).

Trabalhos realizados sobre a capacidade preditiva de produtividade de culturas identifica que os índices de vegetação EVI2 e NDVI, apresentam desempenho positivo e muito próximo na previsão da produtividade da cultura da soja, milho, entre outras culturas, onde o EVI2 apresenta os menores erros de predição, enquanto para a produtividade do milho o EVI2 teve maior destaque preditivo em solos não semiáridos (Bolton; Friedl, 2013.; Andrade Júnior *et al.*, 2022).


A utilização de séries temporais de NDVI e EVI, possibilitam o monitoramento do desenvolvimento da cultura e a modelagem da produtividade com antecedência a colheita, possibilitando a avaliação da biomassa da parte área e a absorção de nutrientes, já nos estágios iniciais de crescimento da cultura (Shammi; Meng, 2021.; Farias *et al.*, 2023).

3 Metodologia

3.1 Caracterização da área

O estudo foi desenvolvido em lavoura comercial de soja do cultivar BMX Valente, semeada no dia 18 de novembro de 2024, com o experimento sendo coletado no dia 15 de abril de 2025, a área da lavoura corresponde a cerca de 11 hectares, localizada em propriedade agrícola no interior do município de Canguçu-RS, na região sul do Estado do Rio Grande do Sul (Figura 1).

Figura 1 Localização da área de estudo



Fonte: Autor, 2025

A área apresenta manejo convencional de soja em sistema mecanizado, com baixo revolvimento de solo, sendo cultivada a soja no verão e semeado azevém (*Lolium multiflorum*) no inverno, o qual é dessecado para que a soja seja semeada sob a palhada do azevém. Para a safra 2024-2025, foi realizada um preparo do solo visando reduzir a compactação do solo, sendo realizada uma escarificação na área.


Segundo Alvares *et al.* (2013), o clima é classificado como Subtropical úmido (Cfa), apresentando temperatura entre -3°C e 18°C no mês mais frio e nos meses quentes apresenta temperatura superior a 22°C , com precipitação bem distribuída ao longo do ano.

3.2 Delineamento amostral e coleta de dados

3.2.1 Amostragem de solo em grade regular

A delimitação da área de estudo foi realizada com base em visitas a campo com utilização de um receptor GNSS (*Global Navigation Satellite System*) modelo Etrex 32x e no software QGIS, versão 3.34. Em seguida, gerou-se uma malha amostral de grade regular no QGIS (Figura 2).

Figura 2 Grade amostral



Fonte: Autor, 2025

Os pontos amostrais foram definidos com uma equidistância horizontal de 45 metros, sendo necessários alguns ajustes no campo para um melhor posicionamento. No total, gerou-se 55 pontos georreferenciados, totalizando 5 pontos por hectare, onde analisaram-se amostras de solo, produtividade e resposta espectral da cultura.

3.2.2 Amostragem de solo

Após a colheita da soja, para caracterizar a variabilidade espacial dos atributos químicos do solo, foram coletadas amostras compostas em cada um dos pontos georreferenciados, 8 subamostras foram coletadas, com trado de rosca, em um raio de 5 metros ao redor do ponto central. As amostras foram coletadas na profundidade de 0,0-0,20m, sendo 6 amostras coletadas nas entrelinhas da cultural e 2 na linha de semeadura (Figura 3).

Figura 3 Amostras de solo coletadas



Fonte: Autor, 2025

As amostras foram coletadas no dia 06 de maio de 2025, sendo devidamente identificadas, armazenadas e encaminhadas para laboratório de análise de solo credenciado à rede ROLAS (Rede Oficial de Laboratórios de Análise de Solo e de Tecido Vegetal dos Estados do Rio Grande do Sul e de Santa Catarina), para ser realizada a análise química completa, incluindo pH em água, cálcio (Ca), magnésio (Mg), relação Ca/Mg, alumínio (Al), acidez potencial (H+Al), capacidade de troca de cátions (CTC) efetiva, saturação por bases, índice SMP, teor de matéria orgânica (MO), argila, enxofre (S), fósforo (P), CTC em pH 7, cobre (Cu), zinco (Z) e boro (B).

Os resultados laboratoriais foram organizados em planilha eletrônica, associando, para cada ponto da grade, as coordenadas geodésicas e os valores dos atributos químicos determinados e posteriormente foram utilizados nas análises estatísticas descritivas e de correlação com a produtividade.

3.2.3 Determinação da produtividade da soja

Em cada ponto amostral, foi determinada a produtividade da soja por meio da colheita de uma parcela de 5m ao redor do ponto georreferenciado. Tendo sido confeccionado um retângulo para facilitar a centralização do ponto e a colheita das plantas. As plantas contidas na parcela foram colhidas manualmente com auxílio de uma foice de mão, trilhadas e o peso dos grãos determinado em balança (Figura 4).

Figura 4 Pesagem de amostras



Fonte: Autor, 2025

Após trilhados, os grãos tiveram sua umidade corrigidas para 13% para então serem pesados em balança de precisão, tendo seu peso posteriormente convertido para produtividade em kg ha^{-1} , para facilitar as análises posteriores.

Em seguida, calculou-se a produtividade média da lavoura, o desvio padrão e o coeficiente de variação (CV), bem como gerou-se um mapa de produtividade por meio de interpolação geoestatística.

3.2.4 Obtenção e processamento de imagens EVI2 do sensor MSI/Sentinel-2

A variabilidade espectral da cultura foi analisada a partir de imagens de EVI2 do sensor MSI a bordo do satélite Sentinel-2, nível de processamento L2A, com uma resolução espacial de 10 m, obtidas junto à plataforma *Google Earth Engine* (GEE), que disponibiliza catálogos de imagens de satélite e ferramentas para cálculo de índices espectrais em larga escala, das quais foram extraídos valores do EVI2, para

toda a área da lavoura. Neste processo, selecionaram-se somente as imagens visualmente livres de cobertura de nuvens durante todo o ciclo da cultura (Tabela 1).

Tabela 1 Data de aquisição das imagens

Imagem	Data
1	17/11/2024
2	16/01/2025
3	05/02/2025
4	10/02/2025
5	07/03/2025
6	19/03/2025
7	28/04/2025

Fonte: Autor, 2025

Além dos valores de EVI2 por data, foram calculadas duas métricas:

- EVI2_P – A variável EVI2_P equivale a soma da curvatura total entre as datas de 16 de janeiro de 2025 a 19 de março de 2025, buscando caracterizar o ciclo de desenvolvimento da cultura.
- EVI2_T – variável correspondente à área sob a curva formada pela série de EVI2 ao longo de todas as sete imagens, sintetizando o vigor espectral integrado da cultura no ciclo.

Sendo assim as imagens obtidas através de sensoriamento remoto orbital, foram utilizadas para analisar a variação espacial com base no EVI2 durante o ciclo da cultura, e a correlação com a produtividade da soja. Não foi possível obter imagens para o mês de dezembro devido à grande presença de nuvens sobre a área durante o mês, o que inviabilizou a utilização das imagens.

3.3 Organização e tratamento preliminar dos dados

Inicialmente, todos os dados de solo, produtividade e EVI2 foram organizados para verificar a presença de valores inconsistentes. A seguir, foram calculadas estatísticas descritivas para todas as variáveis de interesse como média, mediana, valor mínimo, valor máximo, desvio padrão e coeficiente de variação (CV) e teste de normalidade de Lilliefors (1967). Para verificar a suposição de normalidade dos dados de atributos químicos do solo, pré-requisito para a aplicação de testes paramétricos, foi utilizado o teste de normalidade de (Lilliefors, 1967), sendo adotado um nível de

significância de 5%. A maior parte dos atributos apresentou rejeição da hipótese de normalidade, o que fundamentou o uso do teste não paramétrico de correlação de Spearman nas análises seguintes.

A magnitude da variabilidade dos atributos foi interpretada conforme a classificação de Pimentel-Gomes e Garcia (2002), que considera $CV \leq 10\%$ como baixa variabilidade, $10\% < CV \leq 20\%$ como média, $20\% < CV \leq 30\%$ como alta e $CV > 30\%$ como muito alta. Essas análises permitiram caracterizar a variabilidade dos dados e fornecer subsídios para a escolha de métodos estatísticos nas etapas posteriores.

3.4 Análise estatísticas e geoestatísticas

3.4.1 Correlação entre atributos do solo e produtividade

Para analisar a relação entre os atributos químicos do solo e a produtividade da soja, foi calculada a correlação de Spearman entre todas as variáveis de solo e o rendimento em kg ha^{-1} . Essa abordagem permitiu identificar grupos de atributos fortemente correlacionados entre si e, ao mesmo tempo, avaliar a magnitude das associações entre cada atributo e a produtividade da cultura.

3.4.2 Correlação e regressão entre EVI2 e produtividade

A relação entre EVI2 e produtividade foi inicialmente avaliada via correlação de Spearman, calculada entre a produtividade (kg ha^{-1}) e o EVI2 em cada data de imagem, além das variáveis derivadas EVI2_P e EVI2_T. Em seguida, foram ajustados modelos de regressão linear simples, tendo a produtividade como variável dependente e o EVI2 em datas selecionadas e as métricas EVI2_P e EVI2_T como variáveis independentes.

Para cada modelo foram estimados o coeficiente angular e linear, o coeficiente de determinação (R^2) e o nível de significância dos parâmetros, permitindo quantificar a fração da variabilidade produtiva explicada pelo índice de vegetação em diferentes estádios fenológicos da soja. Gráficos de dispersão EVI2 $\times$ produtividade, com as respectivas retas de regressão e intervalos de confiança, foram gerados para auxiliar a interpretação visual das relações.

3.4.3 Interpolação espacial e elaboração de mapas temáticos

A variabilidade espacial da produtividade da soja foi representada por meio de krigagem ordinária, utilizando os valores de produtividade obtidos nos 55 pontos amostrais. A interpolação e a geração dos mapas temáticos foram realizadas no software QGIS, com auxílio do plugin SmartMap, que implementa rotinas de geoestatística para mapeamento digital de atributos agrícolas (Pereira *et al.*, 2022).

Mapas de distribuição espacial de atributos de solo selecionados também foram elaborados a partir dos dados amostrados, permitindo comparar visualmente os padrões de variabilidade de fertilidade com os gradientes de produtividade e de EVI2 no talhão.

3.4 Softwares e ferramentas utilizadas

Para o desenvolvimento deste trabalho foram utilizados diferentes softwares e plataformas digitais. As análises estatísticas descritivas, de correlação, regressão e foram realizadas no software R versão 4.4.0, utilizando scripts próprios e pacotes especializados.

O QGIS versão 3.34 foi empregado para o tratamento e organização dos dados espaciais, incluindo a vetorização da malha amostral, a associação dos pontos às variáveis coletadas em campo e a elaboração de mapas temáticos da área de estudo. O plugin SmartMap, foi empregado para o tratamento dos dados espaciais, krigagem ordinária e elaboração dos mapas temáticos de produtividade e de atributos do solo.

A plataforma Google Earth Engine (GEE) foi utilizada para o processamento de imagens de sensoriamento remoto e para a obtenção dos valores do índice de vegetação EVI2 nos pontos amostrais, os quais foram posteriormente integrados à base de dados para as análises estatísticas e espaciais.


4 Resultados e Discussões

4.1 Produtividade da cultura da soja

A produtividade média da soja no talhão foi de 2.353 kg ha^{-1} , com desvio-padrão de 420 kg ha^{-1} e coeficiente de variação (CV) de 17%. Esses valores indicam um nível de rendimento compatível com o observado em lavouras comerciais sob condições de manejo usuais, porém com variabilidade espacial moderada dentro da área. O CV de 17%, assim como o desvio padrão de quase meia tonelada por hectare, mostra que há diferenças relevantes de produtividade entre os pontos amostrados, sugerindo a existência de subáreas com desempenho superior e inferior que podem ser alvo de manejo diferenciado.

Para visualizar (Figura 5) a distribuição de produtividade na área foi realizada a Krigagem ordinária dos valores pontuais de produtividade, buscando caracterizar a variabilidade espacial da lavoura.

Figura 5 Mapa de distribuição de produtividade



Fonte: Autor, 2025

A imagem da estimativa de produtividade apresenta gradientes de variação dentro da lavoura, sendo possível caracterizar as áreas de alta e baixa produtividade existentes na lavoura. Observa-se uma faixa que vai do Norte ao Nordeste da lavoura que apresenta uma baixa produtividade, enquanto o setor Leste estendendo-se para o centro da lavoura apresenta uma maior produtividade.

4.2 Variabilidade dos atributos químicos do solo

A Tabela 2 apresenta a estatística descritiva dos atributos químicos do solo avaliados nos 55 pontos da malha amostral, incluindo média, mediana, desvio-padrão, coeficiente de variação (CV) e resultado do teste de normalidade.

Tabela 2 Estatística descritiva de atributos físico e químicos do solo na camada de 0,0 – 0,20m.

Variável	Média	Mediana	Desvio Padrão	CV (%)	Normalidade rejeitada
pH	5,93	5,98	0,44	7,34	FALSO
Ca	5,27	5,30	0,76	14,42	FALSO
Mg	1,71	1,70	0,41	24,13	FALSO
Al	0,07	0,00	0,25	349,51	VERDADEIRO
H+Al	3,01	2,70	1,49	49,62	VERDADEIRO
CTC efetiva	7,35	7,20	1,06	14,43	FALSO
Bases	71,27	73,70	10,93	15,34	VERDADEIRO
Índice SMP	6,40	6,42	0,35	5,53	FALSO
MO (%)	2,44	2,40	0,56	22,81	VERDADEIRO
Argila (%)	20,73	22,00	4,48	21,63	VERDADEIRO
S	12,52	12,70	2,99	23,90	VERDADEIRO
P	15,25	11,00	11,13	72,98	VERDADEIRO
CTC pH7	10,27	10,20	1,20	11,66	FALSO
K	107,87	105,00	29,07	26,95	FALSO
Cu	1,64	1,60	0,14	8,59	VERDADEIRO
Zn	1,96	1,90	0,35	17,72	VERDADEIRO
B	0,24	0,24	0,05	19,88	VERDADEIRO
Mn	14,20	12,50	6,22	43,79	VERDADEIRO
C Orgânico	1,38	1,33	0,31	22,81	FALSO
K/CTC	2,71	2,63	0,72	26,64	FALSO
Ca/CTC	51,77	53,10	7,38	14,26	VERDADEIRO
Mg/CTC	17,00	18,20	3,78	22,27	VERDADEIRO
CaMg/K	26,87	26,70	7,44	27,70	VERDADEIRO

Fonte: Autor, 2025

A alta densidade amostral utilizada nesse estudo, sendo de cinco amostras por hectare, supera as recomendações usuais para grades amostrais regulares, que variando em número de amostras por hectare de acordo com a região e com a

necessidade de maior precisão dos dados, possibilitou caracterizar os atributos químicos do solo quanto a sua variabilidade espacial e distribuição na área de cerca de 11 hectares.

De modo geral, observou-se amplo espectro de variabilidade, com atributos situando-se desde a classe de baixa até muito alta variabilidade. No entanto, a maioria dos atributos apresentou $CV > 30\%$, apenas Al, H+Al, P e Mn apresentaram um CV considerado muito alto. A variação de Al é explicada pelo fato do elemento ter sido encontrado em poucos pontos amostrais, bem como a acidez potencial também foi elevada em pontos específicos causando assim uma variação brusca e elevando o CV. Já o fósforo extraído por Mehlich e alguns micronutrientes, como o Mn, são reconhecidos na literatura como atributos de forte variabilidade espacial, frequentemente enquadrados em classes de alta ou muito alta variabilidade em estudo (Guedes Filho *et al.*, 2010).


No que se refere à distribuição dos dados, o teste de normalidade indicou rejeição da hipótese de normalidade para a maior parte dos atributos (por exemplo, Al, H+Al, MO, argila, S, P, Cu, Zn, B, Mn e várias relações entre cátions), enquanto variáveis como pH, Ca, Mg, CTC efetiva, índice SMP, CTC a pH 7, K, C orgânico e K/CTC não tiveram a normalidade rejeitada ao nível de significância de 5%. Esse comportamento, com mistura de distribuições normais, assimétricas e com caudas pesadas, é coerente com estudos que mostram que atributos do solo frequentemente apresentam distribuições não normais em escala de talhão (Delbari; Afrasiab; Loiskandl, 2011.; Stroup, 2015).

Do ponto de vista das condições químicas, a média dos atributos demonstra que o solo apresenta uma boa disponibilidade de nutrientes para as plantas, com a maioria dos macros e micronutrientes em condição de média a alta disponibilidade, com exceção para P, o qual apresenta média classificada como baixa de acordo com o Manual de Calagem e Adubação para os estados do Rio Grande do Sul e Santa Catarina, ainda de acordo com o manual, os valores de pH são ótimos para a cultura da soja, assim como a saturação por bases.

Embora ocorra uma variabilidade espacial com relação aos atributos químicos do solo (Figura 6), alguma deficiência de nutrientes de forma pontual ou problemas devido a acidez potencial que possam afetar a disponibilidade de nutrientes para a soja, de forma geral, os atributos químicos do solo não representam um limitante a produtividade da soja na área de estudo. O P, apresentou valores de muito baixa

disponibilidade em pontos específicos o que resultou em um valor médio classificado como de baixa disponibilidade de P, no entanto, para a maioria dos pontos coletados a disponibilidade de P foi classificada de média a alta.

Figura 6 Distribuição espacial de atributos químicos do solo na área da lavoura



Fonte: Autor, 2025

Os mapas de distribuição espacial das variáveis pH, cálcio, magnésio, matéria orgânica, enxofre e potássio, obtidos a partir dos pontos amostrados, demonstram o quão heterogêneo é a área com relação à distribuição espacial dos atributos químicos


do solo. Embora seja observada essa heterogeneidade com relação aos atributos químicos, áreas com baixos valores estimados de Ca, Mg, S e K, ainda assim são classificadas como áreas com disponibilidades médias e altas, favorecendo uma boa produtividade.

Já para as áreas com os menores valores de pH, o solo ligeiramente ácido pode ser sim, um fator limitante a produtividade, assim como áreas com MO inferior a 2% também pode influenciar na baixa produtividade da soja.

4.3 Relação entre atributos físico e químicos do solo e produtividade da soja

Com base nos testes estatísticos iniciais e na identificação de não normalidade em grande parte dos atributos analisados, foi realizada a correlação de Spearman para buscar identificar quais variáveis do solo apresentam maior correlação com a produtividade da cultura (Figura 7).

Figura 7 Correlação de Spearman entre atributos físico e químicos do solo e produtividade da soja



Apesar da variabilidade encontrada na área representada pela distribuição heterogênea dos atributos no solo na área, a análise de correlação de Spearman entre os atributos de fertilidade e a produtividade da soja indicou associações fracas ou inconsistentes, em geral com coeficientes inferiores a 0,30.

A matriz de correlação de Spearman mostra um forte agrupamento entre os atributos de fertilidade: pH, índice SMP, saturação por bases, Ca, Mg, CTC efetiva, Ca/CTC e Mg/CTC apresentam correlações positivas altas entre si ($r > 0,70$), enquanto se correlacionam negativamente com H+Al, Al, algo esperado em uma análise de solo, tendo em vista que o aumento da saturação por bases está associado à redução da acidez potencial e do Al trocável.


Em relação à produtividade da soja, observa-se que a maior parte dos atributos químicos do solo apresenta correlações fracas ($|r| < 0,30$) ou não expressivas, indicando baixa associação entre os valores pontuais de fertilidade e o rendimento da lavoura. Resultados semelhantes, com baixa correlação entre atributos químicos isolados e produtividade em escala de talhão, têm sido relatados em diferentes culturas e condições de manejo, incluindo soja em Latossolo e Argissolo, reforçando que a produtividade tende a refletir a interação simultânea de múltiplos fatores de solo, clima, relevo e manejo, dificilmente captados por um único atributo químico (Silva *et al.*, 2003.; Buss *et al.*, 2019).

Embora a análise de solo seja uma base importante para a elaboração de zonas de manejo, Bazzi *et al.* (2013), a utilização de propriedades física, químicas e de produtividade para a delimitação de zonas de manejo mostrou uma redução na variância dos atributos analisados, porém, não foi capaz de diferenciar o potencial produtivo nas diferentes zonas de manejo, demonstrando que a análise de solo de forma isolada pode não ser o suficiente em algumas situações.

4.4 Variação espacial do EVI2

As análises quanto às variações espaciais da resposta espectral das culturas podem ser monitoradas já em fase inicial de desenvolvimento (Farias *et al.*, 2023). O desenvolvimento da cultura da soja pode ser observado a partir do dia 16 de janeiro de 2025, sendo acompanhado ao longo do desenvolvimento da cultura (Figura 8).

Figura 8 Variação espacial do EVI2 ao longo do ciclo de desenvolvimento da cultura da soja



Fonte: Autor, 2026

Através das imagens, pode se observar que a variação espacial da resposta espectral da cultura pôde ser caracterizada ao longo de todo o ciclo da cultura, mesmo em momentos de alto acúmulo de biomassa, foi possível verificar a variabilidade espacial a partir do EVI2. Segundo Jiang *et al.* (2008) o EVI2 possui características

similares ao EVI, sendo um índice de vegetação que foi desenvolvido para oferecer maior sensibilidade em regiões de alta biomassa e minimizar a influência do solo, permitindo uma melhor distinção da área e o acompanhamento do ciclo de desenvolvimento da cultura, permitindo distinguir áreas com possíveis problemas de desenvolvimento.


Segundo Sishodia *et al.* (2020), A disponibilidade de imagens de satélite de alta resolução espacial proporcionou um grande aumento no uso do sensoriamento remoto para diversas atividades agrícolas como o monitoramento das culturas. No entanto, para o uso na agricultura a limitação da resolução espectral e temporal pode limitar o uso de imagens de satélite para certas atividades agrícolas.

Porém, o acompanhamento com imagens de satélite e IVs durante a safra, pode possibilitar a identificação de pontos limitantes à produtividade dentro da lavoura. Alguns trabalhos falam sobre a importância do uso de IVs entre eles o EVI2 para o monitoramento do desenvolvimento da cultura e caracterização da produtividade na área (Bolton; Friedl, 2013.; Shammí; Meng, 2021).

4.5 Relação entre produtividade e EVI2

A matriz de correlação de Spearman entre produtividade e os valores de EVI2, extraídos de imagens obtidas de satélite Sentinel-2 foi utilizada para analisar as relações entre tais variáveis em diferentes datas ao longo do ciclo da soja, tendo mostrado uma associação positiva consistente entre EVI2 e a produtividade (Figura 9).

Figura 9 Correlação de Spearman entre EVI2 e produtividade da soja



Fonte: Autor, 2026

Dada a natureza dos dados amostrados, sendo os valores de cada *pixel* obtidos em sete datas distintas, as variáveis EVI2_P e EVI2_T, referem-se ao cálculo da curvatura total discreta, definida pela soma das curvaturas locais em cada vértice. Sendo possível obter duas variáveis que refletem o desenvolvimento da cultura ao longo da safra, EVI2_T abrange o período da semeadura até a colheita e EVI2_P, abrange o período do desenvolvimento vegetativo e acúmulo de biomassa.

Observa-se que o EVI2 obtido nas datas de 17 de novembro de 2025 e 28 de abril de 2026, respectivamente um dia antes da semeadura e dias após a colheita, não apresentaram correlação significativa com a produtividade, conforme o esperado,

tendo em vista que correspondem a data anterior a semeadura e posterior a colheita respectivamente.

Já o EVI2 de 16 de janeiro de 2025, 59 dias após semeadura (DAS), começa a apresentar uma correlação superior a 0,30 com a produtividade, sendo superior a correlação obtida pela maioria dos atributos químicos em relação a produtividade, indo de encontro ao estudo de Farias *et al.* (2023), que descreve a possibilidade da utilização de IVs, para o monitoramento e desenvolvimento da cultura já em fase inicial.

Para as demais datas ao longo do ciclo da cultura, as correlações entre EVI2 e a produtividade mantiveram-se acima de 0,50, superando a maior correlação entre a produtividade e os atributos químicos do solo. A imagem de 5 de fevereiro de 2025, já apresentam uma correlação de 0,64 entre o EVI2 e a produtividade, possibilitando caracterizar na lavoura as áreas de maior potencial produtividade e, principalmente, identificar áreas de baixo potencial produtivo.

A caracterização precoce do potencial produtivo das diferentes áreas da lavoura, possibilita ao produtor a realização de uma análise *in loco*, buscando identificar as possíveis causas do baixo potencial produtivo e realizar um manejo corretivo ainda na safra corrente, quando for observado problemas na resposta espectral da cultura em fase inicial de desenvolvimento, ou antecipar o manejo para a próxima safra.


Para a imagem EVI2 de 7 de março de 2025 (108 DAS), quando a planta se encontra geralmente no final do estágio reprodutivo, na fase de maturação fisiológica, obteve-se o maior índice de correlação positivo entre EVI2 e a produtividade da soja 0,71. Essa imagem é a que melhor representa a variabilidade do potencial produtivo da lavoura.

Os índices compostos EVI2_P e EVI2_T também apresentam correlações positivas altas com a produtividade ($p \approx 0,67$ e $0,64$, respectivamente), reforçando que o comportamento espectral médio da cultura ao longo do ciclo se relaciona de maneira robusta com a produção final.

Em termos práticos, um coeficiente de Spearman em torno de 0,70 indica que cerca de metade da variabilidade da produtividade pode ser associada às variações do EVI2, o que está em linha com estudos que mostram correlações moderadas a altas entre índices de vegetação (NDVI, EVI, EVI2) e produtividade de soja em diferentes escalas (Bolton; Friedl, 2013.; Figueiredo *et al.*, 2016).

Os gráficos de dispersão produtividade x EVI2, acompanhados dos respectivos modelos de regressão linear simples (Figura 10), complementam essa análise ao mostrar a forma da relação e os coeficientes de determinação (R^2). Nas datas em que as correlações de Spearman foram mais altas (16/01/25, 05/02/25, 10/02/25, 07/03/25 e 19/03/25) e para os índices compostos EVI2_P e EVI2_T.

Figura 10 Gráfico de dispersão (produtividade x EVI2)



Fonte: Autor, 2026

Os modelos apresentaram R^2 na faixa aproximada de um terço a cerca de 40% da variabilidade explicada, com nuvens de pontos distribuídas ao longo de uma tendência crescente bem definida e sem padrões evidentes. Isso indica que, nessas janelas fenológicas, o EVI2 não apenas mantém uma relação de concordância com a produtividade, mas também descreve de maneira aproximadamente linear parte importante da sua variação. Estudos de previsão de produtividade de soja em maiores escalas, como Bolton & Friedl (2013) e Ali *et al.* (2022), relatam desempenhos semelhantes ou superiores para IVs quando se consideram séries temporais e janelas

específicas do ciclo, confirmando que esses índices podem explicar parcela significativa da variabilidade de produtividade.

De modo geral, o EVI2 explicou parcela relevante da variabilidade da produtividade em uma lavoura comercial de soja de pequeno porte, convergindo com a literatura que aponta os IVs como ferramentas centrais para a Agricultura de Precisão. Em diferentes contextos, IVs têm se mostrado adequados para representar a variabilidade da cultura e para gerar zonas de manejo eficientes, com reduções expressivas na variância da produtividade dentro das zonas (Speranza *et al.*, 2023).

Estudos mostram, inclusive, que mapas derivados de IVs podem complementar ou até substituir mapas de produtividade na delimitação de zonas de manejo (Damian *et al.*, 2020.; Mazur; Gozdowski; Wójcik-Gront, 2022), e que modelos de predição de rendimento baseados em EVI ou EVI2 tendem a apresentar menores erros de predição em culturas de grãos, como a própria soja (Andrade Júnior *et al.*, 2022.; Tiruneh *et al.*, 2023).

Nesse cenário, o bom desempenho do EVI2 observado neste estudo reforça que índices espectrais capturam a resposta integrada da cultura às condições de solo, meteorológicas e manejo, oferecendo uma via operacional para o diagnóstico da variabilidade produtiva em pequenas, médias e grandes propriedades.

Por fim, é importante reconhecer que o uso de sensoriamento remoto orbital também possui limitações, sobretudo em manejos que exigem intervenções em janelas estreitas do ciclo da cultura, quando a disponibilidade de imagens pode ser comprometida por tempo de revisita e, principalmente, cobertura de nuvens (Weiss; Jacob; Duveiller, 2020).

Ainda assim, o conjunto de evidências recentes incluindo a expansão de estudos multitemporais com soja em diferentes ambientes, que aprofundam o entendimento da resposta espectral da cultura ao longo do seu ciclo de desenvolvimento (Vidican *et al.*, 2023), e o uso de IVs para direcionar amostragem de solo mais eficiente, com menos pontos e maior capacidade de representar a variabilidade (Melo; Cunha; Amaral, 2025), indica que índices de vegetação como o EVI2 se consolidam como eixo estruturante de estratégias de manejo em local específico.

Conclusões

A condução deste estudo em uma lavoura comercial permitiu confirmar que, embora exista variabilidade química do solo em diferentes classes de intensidade, essa heterogeneidade não se traduziu em correlações consistentes com a produtividade da soja, que se manteve em nível compatível com sistemas comerciais, porém com variação espacial moderada.

A análise de correlação de Spearman indicou que a maior parte dos atributos químicos apresentou associações fracas com a produtividade apresentando coeficientes inferiores a 0,30, reforçando que, nas condições avaliadas, a produtividade resultou da ação combinada de múltiplos fatores de solo, meteorológicos, relevo e manejo, e que a amostragem em grade com análise química do solo, isoladamente, apresentou capacidade limitada para explicar a variabilidade produtiva observada.

Por outro lado, o índice de vegetação EVI2 derivado de imagens MSI/Sentinel-2 mostrou associação positiva moderada a alta com a produtividade, com coeficientes de correlação em torno de 0,7 em janelas fenológicas específicas e modelos de regressão explicando cerca de um terço a 40% da variação espacial da produtividade. Com um $R^2 = 0,413$ para a imagem EVI2 obtida 108 DAS. Esses resultados demonstram que o EVI2 foi capaz de representar de forma robusta a variabilidade produtiva no talhão, posicionando-se como uma ferramenta operacional mais sensível que os atributos químicos pontuais para o diagnóstico da lavoura em escala fina.

Por fim os achados indicam que pequenos e médios produtores podem se beneficiar do uso sistemático de índices de vegetação, obtidos a baixo custo a partir de sensores orbitais, para identificar subáreas com diferentes níveis de desempenho e orientar intervenções de manejo direcionados para correção do solo, ajuste de insumos ou monitoramento de estresses ao longo do ciclo, visando a sustentabilidade do sistema do ponto de vista econômico e ambiental.

Referências

ALI, A.; RONDELLI, V.; MARTELLI, R.; FALSONE, G.; LUPIA, F.; BARBANTI, L. Management Zones Delineation through Clustering Techniques Based on Soils Traits, NDVI Data, and Multiple Year Crop Yields. **Agriculture**, Basel, Suíça, v. 12, n. 2, 231, 2022. Disponível em: <https://doi.org/10.3390/agriculture12020231>. Acesso em: 10 dez. 2025.

ANDRADE JÚNIOR, A. S. de *et al.* Predição da produtividade de grãos de soja utilizando imagens aéreas de drone. **Revista Brasileira de Engenharia Agrícola e Ambiental** (Agriambi), Campina Grande, PB, v. 26, n. 6, p. 466-476, 2022. <http://dx.doi.org/10.1590/1807-1929/agriambi.v26n6p466-476>. Acesso em: 12 dez. 2025.

BAZZI, C. L., SOUZA, E. G., URIBE-OPAZO, M. A., NOBREGA, L. H. P., ROCHA, D. M. Management zones definition using soil chemical and physical attributes in a soybean area. **Agricultural Engineering**, 33(5), 952-964, out. 2013. Disponível em: <https://doi.org/10.1590/S0100-69162013000500007>. Acesso em: 15 jan. 2026

BENEDUZZI, H. M.; SOUZA, E. G. de; MOREIRA, W. K. O.; SOBJAK, R.; BAZZI, C. L.; RODRIGUES, M. Fertilizer recommendation methods for precision agriculture - a systematic literature study. **Engenharia Agrícola**, Jaboticabal, v. 42, n. 1, e20210185, 2022. Disponível em: <http://dx.doi.org/10.1590/1809-4430-Eng.Agric.v42n1e20210185/2022>. Acesso em: 16 jan. 2026.

BERNARDI, A. C. C.; TUPY, O.; SANTOS, K. E. L.; MAZZUCO, G. G.; BETTIOL, G. M.; RABELLO, L. M.; INAMASU, R. Y. Mapping of yield, economic return, soil electrical conductivity, and management zones of irrigated corn for silage. **Pesquisa Agropecuária Brasileira**, Brasília, v. 54, e00305, p. 1-9, 2018. Disponível em: <http://dx.doi.org/10.1590/S0100-204X2018001200001>. Acesso em: 12 dez. 2025.

BOLTON, D. K.; FRIEDL, M. A. Forecasting crop yield using remotely sensed vegetation indices and crop phenology metrics. **Agricultural and Forest Meteorology**, v. 173, p. 74-84, 2013. Disponível em: <http://dx.doi.org/10.1016/j.agrformet.2013.01.007>. Acesso em: 12 nov. 2025.

BOTTEGA, E. L.; QUEIROZ, D. M. de; PINTO, F. de A. de C.; VALENTE, D. S. M.; SOUZA, C. M. A. de. Precision agriculture applied to soybean crop: Part II - Temporal stability of management zones. **Australian Journal of Crop Science**, [s. l.], v. 11, n. 6, p. 676-682, 2017. Disponível em: <https://doi.org/10.21475/ajcs.17.11.06.p382>. Acesso em: 14 jan. 2026.

BUSS, R. N. et al. Spatial and multivariate analysis of soybean productivity and soil physical-chemical attributes. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 23, n. 6, p. 446-453, 2019. Disponível em: <https://doi.org/10.1590/1807-1929/agriambi.v23n6p446-453>. Acesso em: 10 dez. 2025.

CARNEIRO, J. S. S.; FARIA, Á. J. G. de; FIDELIS, R. R.; SILVA NETO, S. P. da; SANTOS, A. C. dos; SILVA, R. R. da. Diagnóstico da variabilidade espacial e

manejo da fertilidade do solo no Cerrado. **Scientia Agraria**, Curitiba, v. 17, n. 3, p. 38-49, jul./dez. 2016. Disponível em: <https://revistas.ufpr.br/agraria>. Acesso em: 10 jan. 2026.

CHERUBIN, M.R., SANTI, A.L., BASSO, C.J., EITELWEIN, M.T., 2015. Sampling grid size for characterization of the spatial variability of phosphorus and potassium in an Oxisol. **Pesquisa Agropecuária Brasileira** 50(2), 168–177. Disponível em: <https://doi.org/10.1590/S0100-204X2015000200009>. Acesso em: 17 jan. 2026.

CHERUBIN, M. R. et al. Precision Agriculture in Brazil: The Trajectory of 25 Years of Scientific Research. **Agriculture**, v. 12, n. 11, 1882, 9 nov. 2022. Disponível em: <https://doi.org/10.3390/agriculture12111882>. Acesso em: 17 jan. 2026.

DAMIAN, J. M.; PIAS, O. H. de C.; CHERUBIN, M. R.; FONSECA, A. Z. da; FORNARI, E. Z.; SANTI, A. L. Applying the NDVI from satellite images in delimiting management zones for annual crops. **Scientia Agricola**, Piracicaba, 2020. Disponível em: <http://dx.doi.org/10.1590/1678-992X-2018-0055>. Acesso em: 17 jan. 2026.

DELBARI, M.; AFRASIAB, P.; LOISKANDL, W. Geostatistical Analysis of Soil Texture Fractions on the Field Scale. **Soil & Water Research**, [s. l.], v. 6, n. 4, p. 173-189, 2011. Disponível em: <https://swr.agriculturejournals.cz/pdfs/swr/2011/04/04.pdf>. Acesso em: 15 jan. 2026.

DOGAR, S. S. et al. Combining electromagnetic induction and satellite-based NDVI data for improved determination of management zones for sustainable crop production. **SOIL**, v. 11, n. 4, p. 655-679, 25 set. 2025. Disponível em: <https://doi.org/10.5194/soil-11-655-2025>. Acesso em: 10 dez. 2025.

FARIAS, G. D. et al. Normalized Difference Vegetation Index (NDVI) for soybean biomass and nutrient uptake estimation in response to production systems and fertilization strategies. **Frontiers in Sustainable Food Systems**, v. 6, 959681, 9 jan. 2023. Disponível em: <https://doi.org/10.3389/fsufs.2022.959681>. Acesso em: 10 dez. 2025.

FIGUEIREDO, G. K. D. A. et al. Correlation maps to assess soybean yield from EVI data in Paraná State, Brazil. **Scientia Agricola**, Piracicaba, v. 73, n. 6, p. 462-470, nov./dez. 2016. Disponível em: <https://doi.org/10.1590/0103-9016-2015-0215>. Acesso em: 17 jan. 2026.

GASCON, F. et al. Copernicus Sentinel-2A Calibration and Products Validation Status. **Remote Sensing**, v. 9, n. 6, p. 584, 2017. Disponível em: <https://www.mdpi.com/2072-4292/9/6/584>. Acesso em: 04 fev. 2026.

GETAHUN, S.; KEFALE, H.; GELAYE, Y. Application of Precision Agriculture Technologies for Sustainable Crop Production and Environmental Sustainability: A Systematic Review. **The Scientific World Journal**, v. 2024, art. ID 2126734, 2024. Disponível em: <https://doi.org/10.1155/2024/2126734>. Acesso em: 05 jan. 2026.

GONÇALVES, J. R. M. R.; FERRAZ, G. A. S.; REYNALDO, É. F.; MARIN, D. B.; FERRAZ, P. F. P. Comparative economic analysis of soil sampling methods used in precision agriculture. **Anais da Academia Brasileira de Ciências**, Rio de Janeiro, v. 92, n. supl. 1, e20190277, 2020. Disponível em: <https://doi.org/10.1590/0001-3765202020190277>. Acesso em: 17 dez. 2025.

GUEDES FILHO, O.; VIEIRA, S. R.; CHIBA, M. K.; NAGUMO, C. H.; DECHEN, S. C. F. Spatial and temporal variability of crop yield and some Rhodic Hapludox properties under no-tillage. **Revista Brasileira de Ciência do Solo** 1, Viçosa, v. 34, n. 1, p. 1- 14, jan./fev. 2010. Disponível em: <https://www.redalyc.org/pdf/1802/180215873001.pdf> Acesso em: 18 jan. 2026.

GUEDES, L. P. C.; RIBEIRO JUNIOR, P. J.; URIBE-OPAZO, M. A.; BASTIANI, F. de. Soybean yield maps using regular and optimized sample with different configurations by simulated annealing. **Engenharia Agrícola**, Jaboticabal, v. 36, n. 1, p. 114-125, jan./fev. 2016. Disponível em: <http://dx.doi.org/10.1590/1809-4430-Eng.Agric.v36n1p114-125/2016>. Acesso em: 17 jan. 2026.

GUIMARÃES, F. H. C.; CUNHA, J. P. A. R. da; HURTADO, S. M. C. Delineation of management zones in a grain production area. **Bioscience Journal**, Uberlândia, v. 40, e40052, 2024. Disponível em: <https://doi.org/10.14393/BJ-v40n0a2024-65297>. Acesso em: 14 jan. 2026.

JIANG, Z.; HUETE, A. R.; DIDAN, K.; MIURA, T. Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, v. 112, n. 10, p. 3833-3845, out. 2008. Disponível em: <https://doi.org/10.1016/j.rse.2008.06.006>. Acesso em: 17 nov. 2025.

JOVANOVIĆ, D. et al. Multi-Source Data Integration for Sustainable Management Zone Delineation in Precision Agriculture. **Sustainability**, v. 17, n. 15, 6931, 30 jul. 2025. Disponível em: <https://doi.org/10.3390/su17156931>. Acesso em: 10 dez. 2025.

LAWRENCE, P. G.; ROPER, W.; MORRIS, T. F.; GUILLARD, K. Guiding soil sampling strategies using classical and spatial statistics: A review. **Agronomy Journal**, v. 112, p. 493–510, 2020. Disponível em: <https://doi.org/10.1002/agj2.20048>. Acesso em: 20 nov. 2025.

LILLIEFORS, H. W. On the Kolmogorov-Smirnov test for normality with mean and variance unknown. **Journal of the American Statistical Association**, v. 62, n. 318, p. 399-402, 1967.

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. Disponível em: <https://doi.org/10.1023/B:PRAG.0000022358.24102.1b>. Acesso em: 20 nov. 2025.

MALTAURO, T. C.; URIBE-OPAZO, M. A.; GUEDES, L. P. C.; GALEA, M.; NICOLIS, O. Spatial-Temporal Variability of Soybean Yield Using Separable Covariance Structure. **Agriculture**, v. 15, n. 6, 1199, p. 1-21, 31 maio 2025.

Disponível em: <https://doi.org/10.3390/agriculture15111199>. Acesso em: 04 jan. 2026.

MAZUR, P.; GOZDOWSKI, D.; WÓJCIK-GRONT, E. Soil Electrical Conductivity and Satellite-Derived Vegetation Indices for Evaluation of Phosphorus, Potassium and Magnesium Content, pH, and Delineation of Within-Field Management Zones. **Agriculture**, v.12,n.6, 883, 19 jun. 2022. Disponível em: <https://doi.org/10.3390/agriculture12060883>. Acesso em: 08 dez. 2025.

MELO, D. D.; CUNHA, I. A.; AMARAL, L. R. Hierarchical Stratification for Spatial Sampling and Digital Mapping of Soil Attributes. **AgriEngineering**, v. 7, n. 1, 10, 2025. Disponível em: <https://doi.org/10.3390/agriengineering7010010>. Acesso em: 10 jan. 2026.

MISHRA, P. N. et al. A Review on Precision Agriculture: Leveraging Variable Rate Application and Machine Learning for Sustainable and Profitable Farming. **International Journal of Environmental Sciences**, v. 11, n. 4s, 2025. Disponível em: https://www.researchgate.net/publication/392923239_A_Review_on_Precision_Agriculture_Leveraging_Variable_Rate_Application_and_Machine_Learning_for_Sustainable_and_Profitable_Farming. Acesso em: 05 jan. 2026.

MOLIN, J. P.; BAZAME, H. C.; MALDANER, L.; CORREDO, L. P.; MARTELLO, M.; CANATA, T. F. Precision agriculture and the digital contributions for site-specific management of the fields. **Revista Ciência Agronômica**, Fortaleza, v. 51, n. especial, e20207720, 2020. Disponível em: <https://doi.org/10.5935/1806-6690.20200088>. Acesso em: 15 dez. 2025.

MOLIN, J. P.; TAVARES, T. R. Sensor systems for mapping soil fertility attributes: challenges, advances, and perspectives in Brazilian tropical soils. **Engenharia Agrícola**, Jaboticabal, v. 39, n. especial, p. 126-147, 2019. DOI: Disponível em: <http://dx.doi.org/10.1590/1809-4430-Eng.Agric.v39nep126-147/2019>. Acesso em: 05 dez. 2025.

NANNI, M. R. et al. Optimum size in grid soil sampling for variable rate application in site-specific management. **Scientia Agrícola**, Piracicaba, v. 68, n. 3, p. 386-392, maio/jun. 2011. Disponível em: <https://doi.org/10.1590/S0103-90162011000300017>. Acesso em: 12 dez. 2025.

NAWAR, S.; MULLA, D. J.; MOUAZEN, A. M. Delineation of Soil Management Zones for Variable-Rate Fertilization: A Review. **Advances in Agronomy**, [s. l.], v. 143, p. 175-245, 2017. Disponível em: <https://doi.org/10.1016/bs.agron.2017.01.003>. Acesso em: 06 jan. 2026.

NETO, A. J. P. et al. Temporal and spatial variability of soybean yield in different management zones. **Revista Ciência Agronômica**, Fortaleza, v. 51, n. 3, e20176043, p. 1-8, 2020. Disponível em: https://www.cropj.com/neto_14_9_2020_1465_1472.pdf. Acesso em: 06 jan. 2026.

ONYANGO, C. M.; NYAGA, J. M.; WETTERLIND, J.; SÖDERSTRÖM, M.; PIIKKI, K. Precision Agriculture for Resource Use Efficiency in Smallholder Farming

Systems in Sub-Saharan Africa: A Systematic Review. **Sustainability**, v. 13, n. 3, 1158, 22 jan. 2021. Disponível em: <https://doi.org/10.3390/su13031158>. Acesso em: 06 jan. 2026.

PEREIRA, G. W.; VALENTE, D. S. M.; QUEIROZ, D. M. de; COELHO, A. L. de F.; COSTA, M. M.; GRIFT, T. Smart-Map: An Open-Source QGIS Plugin for Digital Mapping Using Machine Learning Techniques and Ordinary Kriging. **Agronomy**, [s. l.], v. 12, n. 6, 1350, p. 1-20, 3 jun. 2022. Disponível em: <https://doi.org/10.3390/agronomy12061350>. Acesso em: 18 nov. 2025.

PIMENTEL-GOMES, Frederico e GARCIA, Carlos Henrique. **Estatística aplicada a experimentos agrônômicos e florestais: exposição com exemplos e orientações para uso de aplicativos**. Piracicaba, SP: FEALQ. Disponível em: <https://repositorio.usp.br/item/001309130> . Acesso em: 20 jan. 2026.

PRINCE CZARNECKI, Joby M. et al. A brief history of remote sensing of soybean. **Agronomy Journal**, [S. l.], v. 117, n. 1, p. 1-17, 2025. Disponível em: <https://doi.org/10.1002/agj2.70004>. Acesso em: 07 jan. 2026.

RADOČAJ, D.; ŠILJEG, A.; MARINOVIĆ, R.; JURIŠIĆ, M. State of Major Vegetation Indices in Precision Agriculture Studies Indexed in Web of Science: A Review. **Agriculture**, v. 13, n. 3, 707, p. 1-21, 18 mar. 2023. Disponível em: <https://doi.org/10.3390/agriculture13030707>. Acesso em: 12 dez. 2025.

ROMANO, E. et al. Stability maps using historical NDVI images on durum wheat to understand the causes of spatial variability. **Precision Agriculture**, v. 26, 26, 28 jan. 2025. Disponível em: <https://doi.org/10.1007/s11119-025-10222-8>. . Acesso em: 18 dez. 2025.

RUDER, S.-L.; FAXON, H. O.; ORZEL, E. C.; DEVKOTA, R.; BRONSON, K. Reviewing the evidence on precision agriculture and environmental sustainability. **Npj Sustainable Agriculture**, [s. l.], v. 4, n. 9, p. 1-11, 2026. Disponível em: <https://doi.org/10.1038/s44264-026-00128-x>. Acesso em: 20 jan. 2026.

SAHA, S. et al. Precision agriculture for improving crop yield predictions: a literature review. **Frontiers in Agronomy**, v. 7, art. 1566201, 21 jul. 2025. Disponível em: <https://doi.org/10.3389/fagro.2025.1566201>. Acesso em: 04 jan. 2026.

SHAMMI, S. A.; MENG, Q. Use time series NDVI and EVI to develop dynamic crop growth metrics for yield modeling. **Ecological Indicators**, v. 121, 107124, 2021. Disponível em: <https://doi.org/10.1016/j.ecolind.2020.107124>. Acesso em: 06 jan. 2026.

SILVA, V. R. et al. Variabilidade espacial das características químicas do solo e produtividade de milho em um Argissolo Vermelho-Amarelo distrófico arênico. **Revista Brasileira de Ciência do Solo**, v. 27, n. 6, p. 1013-1020, 2003. Disponível em: <http://dx.doi.org/10.1590/S0100-06832003000600005>. Acesso em: 15 dez. 2025.

SISHODIA, R. P.; RAY, R. L.; SINGH, S. K. Applications of Remote Sensing in Precision Agriculture: A Review. **Remote Sensing**, v. 12, n. 19, 3136, 24 set. 2020. Disponível em: <https://doi.org/10.3390/rs12193136>. Acesso em: 10 dez. 2025.

SPERANZA, E. A. et al. Delineating management zones with different yield potentials in soybean-corn and soybean-cotton production systems. **AgriEngineering**, Basel, Suíça, v. 5, n. 3, p. 1481-1497, 2023. Disponível em: <https://doi.org/10.3390/agriengineering5030092>. Acesso em: 20 nov. 2025.

STROUP, W. W. Rethinking the Analysis of Non-Normal Data in Plant and Soil Science. **Agronomy Journal**, [s. l.], v. 107, n. 2, p. 811-827, 2015. Disponível em: <https://doi.org/10.2134/agronj2013.0342>. Acesso em: 12 jan. 2026.

TIRUNEH, G. A. et al. Mapping crop yield spatial variability using Sentinel-2 vegetation indices in Ethiopia. **Arabian Journal of Geosciences**, v. 16, 631, 2023. Disponível em: <https://doi.org/10.1007/s12517-023-11754-x>. Acesso em: 10 dez. 2025.

TOLOI, M. N. V. et al. Development Indicators and Soybean Production in Brazil. **Agriculture**, v. 11, n. 11, 1164, 18 nov. 2021. Disponível em: <https://doi.org/10.3390/agriculture11111164>. Acesso em: 04 jan. 2026.

UNITED NATIONS DEVELOPMENT PROGRAMME. **Precision Agriculture for Smallholder Farmers. Singapore: UNDP Global Centre for Technology, Innovation and Sustainable Development**, 2021. 80 p. Disponível em: <https://sgtechcentre.undp.org>. Acesso em: 20 jan. 2026.

VALDES, C.; GILLESPIE, J.; DOHLMAN, E. **Soybean production, marketing costs, and export competitiveness in Brazil and the United States**. Washington, DC: U.S. Department of Agriculture, Economic Research Service, 2023. 26 p. (Economic Information Bulletin, n. 262). Disponível em: <https://doi.org/10.22004/ag.econ.340506>. Acesso em: 05 jan. 2026.

VALENTE, D. S. M. et al. Accuracy of Various Sampling Techniques for Precision Agriculture: A Case Study in Brazil. **Agriculture**, v. 14, n. 12, 2198, 1 dez. 2024. Disponível em: <https://doi.org/10.3390/agriculture14122198>. Acesso em: 05 jan. 2026.

VIDICAN, R. et al. Using Remote Sensing Vegetation Indices for the Discrimination and Monitoring of Agricultural Crops: A Critical Review. **Agronomy**, v. 13, n. 12, 3040, 12 dez. 2023. <https://doi.org/10.3390/agronomy13123040>. Acesso em: 18 jan. 2026.

VULLAGANTI, N.; RAM, B. G.; SUN, X. Precision agriculture technologies for soil site- specific nutrient management: A comprehensive review. **Artificial Intelligence in Agriculture**, [s. l.], v. 15, p. 147-161, 2025. Disponível em: <https://doi.org/10.1016/j.aiia.2025.02.001>. Acesso em: 22 jan. 2026.

WEISS, M.; JACOB, F.; DUVEILLER, G. Remote sensing for agricultural

applications: A meta-review. **Remote Sensing of Environment**, v. 236, 111402, jan. 2020. Disponível em: <https://doi.org/10.1016/j.rse.2019.111402>. Acesso em: 18 jan. 2026.

XUE, J.; SU, B. Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. **Journal of Sensors**, v. 2017, 1353691, 23 maio 2017. Disponível em: <https://doi.org/10.1155/2017/1353691>. Acesso em: 10 dez. 2025.

YAN, K.; GAO, S.; YAN, G.; MA, X.; CHEN, X.; ZHU, P.; LI, J.; GAO, S.; GASTELLU- ETCHEGORRY, J.-P.; MYNENI, R. B.; WANG, Q. A global systematic review of the remote sensing vegetation indices. **International Journal of Applied Earth Observation and Geoinformation**, [s. l.], v. 139, 104560, p. 1-22, 2025. Disponível em: <https://doi.org/10.1016/j.jag.2025.104560>. Acesso em: 15 jan. 2026.