

UNIVERSIDADE FEDERAL DE VIÇOSA

Delimitação de zonas de manejo com base em dados temporais do sentinel-1

Juliano de Paula Gonçalves
Doctor Scientiae

**VIÇOSA - MINAS GERAIS
2025**

JULIANO DE PAULA GONÇALVES

Delimitação de zonas de manejo com base em dados temporais do sentinel-1

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Doctor Scientiae*.

Orientador: Francisco de A. de C. Pinto

Coorientadores: Daniel M. de Queiroz
Domingos S. M. Valente

**VIÇOSA - MINAS GERAIS
2025**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade
Federal de Viçosa - Campus Viçosa**

T

G635d
2025
Gonçalves, Juliano de Paula, 1992-
Delimitação de zonas de manejo com base em dados
temporais do sentinel-1 / Juliano de Paula Gonçalves. – Viçosa,
MG, 2025.
1 tese eletrônica (90 f.)

Orientador: Francisco de Assis de Carvalho Pinto.
Tese (doutorado) - Universidade Federal de Viçosa,
Departamento de Engenharia Agrícola, 2025.

Inclui bibliografia.

DOI: <https://doi.org/10.47328/ufvbbt.2025.518>

Modo de acesso: World Wide Web.

1. Agricultura de precisão. 2. Sensoriamento remoto.
3. Solos - Amostragem. I. Pinto, Francisco de Assis de Carvalho,
1964-. II. Universidade Federal de Viçosa. Departamento de
Engenharia Agrícola. Programa de Pós-Graduação em
Engenharia Agrícola. III. Título.

CDD 22. ed. 631.3

JULIANO DE PAULA GONÇALVES

Delimitação de zonas de manejo com base em dados temporais do sentinel-1

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de *Doctor Scientiae*.

APROVADA: 20 de março de 2025.

Assentimento:

Juliano de Paula Gonçalves
Autor

Francisco de Assis de Carvalho Pinto
Orientador

Essa tese foi assinada digitalmente pelo autor em 15/08/2025 às 12:55:37 e pelo orientador em 15/08/2025 às 16:26:26. As assinaturas têm validade legal, conforme o disposto na Medida Provisória 2.200-2/2001 e na Resolução nº 37/2012 do CONARQ. Para conferir a autenticidade, acesse <https://siadoc.ufv.br/validar-documento>. No campo 'Código de registro', informe o código **MA93.RA8G.47TU** e clique no botão 'Validar documento'.

A Deus e aos meus pais Vicente de Paula Gonçalves e Cleusa Aparecida Pinto
Gonçalves, pelo amor, carinho, incentivo e confiança.

AGRADECIMENTOS

À Deus, por estar ao meu lado em cada momento da minha jornada na Universidade Federal de Viçosa, especialmente nos momentos de dificuldade, quando pensei que não conseguiria chegar até aqui. Sou grato pela saúde e pelo dom do conhecimento, que me permitiram contribuir para a construção de um mundo melhor por meio desta pesquisa.

Aos meus pais Vicente de Paula Gonçalves e Cleusa Aparecida Pinto Gonçalves e minha irmã Bruna de Paula Gonçalves por todo esforço, incentivo, carinho e compreensão desde o período escolar até a universidade. Todas as conquistas que obtive na vida foram graças a vocês. Obrigado por tudo e serei eternamente grato.

Ao amigo e professor Dr. Francisco de Assis de Carvalho Pinto, que esteve ao meu lado como orientador desde 2014. Sua competência e dedicação em ensinar foram fundamentais para meu crescimento, permitindo-me conquistar oportunidades tanto na vida acadêmica quanto profissional. Sou grato pelo incentivo constante a ir além no conhecimento. Obrigado por tudo.

Aos amigos e Coorientadores, Dr. Daniel Marçal de Queiroz e Dr. Domingos Sárvio Magalhães Valente, pelos conhecimentos compartilhados e principalmente por acreditarem e motivarem a desenvolver um trabalho de qualidade.

Agradeço à GDM Seeds pela oportunidade profissional e pelo incentivo contínuo aos meus estudos. Sem seu apoio, a realização desta pesquisa não teria sido possível.

Por fim, agradeço a todos os familiares e amigos que, mesmo não mencionados aqui, contribuíram de alguma forma para que eu pudesse alcançar este momento.

Este trabalho foi realizado com o apoio das seguintes agências de pesquisa brasileiras: Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001, Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

RESUMO

GONÇALVES, Juliano de Paula, D.Sc., Universidade Federal de Viçosa, março de 2025. **Delimitação de zonas de manejo com base em dados temporais do sentinel-1**. Orientador: Francisco de Assis de Carvalho Pinto. Coorientadores: Daniel Marcal de Queiroz e Domingos Sarvio Magalhaes Valente.

A caracterização da variabilidade dos atributos do solo geralmente demanda grades de amostragem com alta densidade, o que pode resultar em custos significativos de coleta e análise laboratorial. Uma possível solução é delimitar Zonas de Manejo (ZMs) com base em dados previamente coletados para direcionar o processo de amostragem. O objetivo desta pesquisa foi avaliar o potencial de aplicação dos dados de radar na delimitação de ZMs. Para isso, foram estabelecidos os seguintes objetivos específicos: (1) desenvolver um método para mapear atributos do solo por meio da delimitação de ZMs utilizando dados de radar do Sentinel-1 (2) comparar o método desenvolvido com métodos tradicionais de amostragem na estimativa dos atributos do solo (3) avaliar a acurácia das ZMs definidas com base no índice VV/VH do Sentinel-1 na estimativa de atributos do solo, em relação a métodos convencionais que tem por base mapas de produtividade e índice NDVI (4) avaliar a acurácia das ZMs delimitadas pelos índices NDVI e VV/VH na previsão da produtividade média padronizada, utilizando mapas de produtividade coletados ao longo dos anos. Imagens do Sentinel-1 foram usadas para gerar o perfil temporal de seis índices com base nas bandas de retroespalhamento VV (vertical-vertical) e VH (vertical-horizontal) entre janeiro de 2018 e março de 2023 em 3 campos agrícolas. Para delimitar as ZMs, os índices e as bandas foram analisados individualmente por duas abordagens: (1) agrupamento fuzzy k-means aplicado às séries temporais dos índices e (2) redução de dimensionalidade via autoencoders, seguida de um agrupamento fuzzy k-means. A melhor combinação de índice e abordagem foi comparada com quatro métodos tradicionais de mapeamento de atributos do solo: amostra única composta, grade uniforme (1 amostra/ha), células retangulares (5-10 ha) e células geradas aleatoriamente. A validação cruzada deixo-um-de-fora foi utilizada para avaliar o desempenho dos métodos. Os resultados obtidos mostraram que a combinação do índice VV/VH com o algoritmo autoencoders para a delimitação de ZMs proporcionou estimativas mais precisas dos atributos do solo e superou o método convencional de amostragem do solo (uma única amostra composta) e, em muitos casos, o método de amostragem do solo por células. Em comparação com as abordagens tradicionais de delimitação de ZMs, que utilizam mapas de produtividade e NDVI, o método desenvolvido

apresentou acurácia semelhante na maioria dos atributos do solo, com destaque para o atributo argila, onde seu desempenho foi significativamente superior. Ambos os métodos NDVI e VV/VH identificaram zonas de alta e baixa produtividade com comportamento similares. Os resultados deste estudo destacam o índice VV/VH do Sentinel-1 como uma alternativa viável para a delimitação de ZMs. Entretanto, mais estudos são necessários para validar sua aplicação em diferentes condições ambientais, avaliar sua estabilidade ao longo do tempo e explorar possíveis melhorias na estratégia de processamento das séries temporais do índice VV/VH.

Palavras-chave: Agricultura de precisão, Sensoriamento Remoto, Amostragem de solo, Radar de Abertura Sintética, Aprendizado Profundo

ABSTRACT

GONÇALVES, Juliano de Paula, D.Sc., Universidade Federal de Viçosa, March, 2025. **Management zone delimitation based on temporal data from Sentinel-1.** Adviser: Francisco de Assis de Carvalho Pinto. Co-advisers: Daniel Marcal de Queiroz and Domingos Sarvio Magalhaes Valente.

The characterization of soil attribute variability often requires high-density sampling grids, which can lead to significant costs in data collection and laboratory analysis. A possible solution is to delineate Management Zones (MZs) based on previously collected data to guide the sampling process. This study aimed to evaluate the potential application of radar data in MZs delineation. To achieve this, the following specific objectives were established: (1) develop a method to map soil attributes by delineating MZs using radar data from Sentinel-1 (2) compare the developed method with traditional soil sampling methods in estimating soil attributes (3) evaluate the accuracy of MZs defined based on the Sentinel-1 VV/VH index in estimating soil attributes, in comparison to conventional methods based on productivity maps and the NDVI index (4) assess the accuracy of MZs delineated using NDVI and VV/VH indices in predicting standardized average productivity, using productivity maps collected over the years. Sentinel-1 images were used to generate the temporal profile of six indices based on VV (vertical-vertical) and VH (vertical-horizontal) backscatter bands between January 2018 and March 2023 in three agricultural fields. To delineate MZs, the indices and bands were analyzed individually using two approaches: (1) fuzzy k-means clustering applied to the temporal series of indices and (2) dimensionality reduction via autoencoders, followed by fuzzy k-means clustering. The best combination of index and approach was compared with four traditional soil attribute mapping methods: composite single sample, uniform grid (1 sample/ha), rectangular cells (5-10 ha), and randomly generated cells. Leave-one-out cross-validation was used to assess the performance of the methods. The results showed that the combination of the VV/VH index with the autoencoder algorithm for MZs delineation provided more accurate soil attribute estimates, outperforming the conventional soil sampling method (composite single sample) and, in many cases, the soil sampling method based on cells. In comparison with traditional approaches for delineating MZs, which use yield maps and NDVI, the developed method demonstrated similar accuracy for most soil attributes, with a notable improvement in the estimation of clay content, where its performance was significantly superior. Both NDVI and VV/VH methods identified high- and low-productivity zones with similar behavior.

The findings of this study highlight the Sentinel-1 VV/VH index as a viable alternative for MZs delineation. However, further studies are needed to validate its application under different environmental conditions, assess its stability over time, and explore potential improvements in the processing strategy of the VV/VH index time series.

Keywords: Precision Agriculture, Remote Sensing, Soil Sampling, Synthetic Aperture Radar, Deep Learning

SUMÁRIO

1	INTRODUÇÃO GERAL.....	11
1.1	REFERÊNCIAS.....	15
2	ARTIGO I - MAPEAMENTO DE ATRIBUTOS DO SOLO COM BASE EM ZONAS DE MANEJO DELIMITADAS A PARTIR DE DADOS DE RADAR SENTINEL-1	19
	RESUMO.....	19
	ABSTRACT	20
2.1	INTRODUÇÃO	21
2.2	MATERIAL E MÉTODOS	23
2.2.1	Área de Estudo.....	23
2.2.2	Conjunto de dados e pré-processamento Sentinel-1.....	24
2.2.3	Geração de perfis temporais e índices SAR.....	26
2.2.4	Delimitação de zonas de manejo usando dados SAR	27
2.2.5	Validação das zonas de manejos geradas a partir de dados SAR.....	30
2.2.6	Avaliação de métodos de amostragem.....	31
2.3	RESULTADOS.....	33
2.3.1	Análise exploratória do conjunto de dados SAR.....	33
2.3.2	Análise exploratória do conjunto de dados de solo	36
2.3.3	Delimitação de Zonas de Manejo com SAR.....	39
2.3.4	Comparação de Métodos de Amostragem de Solo	43
2.4	DISCUSSÃO.....	44
2.5	CONCLUSÃO	49
2.6	REFERÊNCIAS	49
3	ARTIGO II - POTENCIAL DA SÉRIE TEMPORAL DO ÍNDICE VV/VH DO SENTINEL-1 NA DELIMITAÇÃO DE ZONAS DE MANEJO	57
	RESUMO.....	57
	ABSTRACT	58
3.1	INTRODUÇÃO	59
3.2	MATERIAL E MÉTODOS	62
3.2.1	Local de estudo e conjunto de dados.....	62
3.2.2	Imagens de sensoriamento remoto	65
3.2.3	Delimitação de Zonas de Manejo	66
3.2.4	Análise estatística	69
3.3	RESULTADOS E DISCUSSÃO.....	70
3.4	CONCLUSÃO	82
3.5	REFERÊNCIAS.....	83

4. CONCLUSÃO GERAL.....	90
-------------------------	----

1 INTRODUÇÃO GERAL

Diante do aumento dos custos dos insumos agrícolas, a otimização da gestão dos recursos torna-se fundamental, demandando a adoção de tecnologias que aprimorem a compreensão das variáveis envolvidas no processo produtivo (Serrano et al., 2023). A Agricultura de Precisão (AP), impulsionada pela integração de sensores inteligentes e tecnologias avançadas, tem se consolidado como uma abordagem inovadora, promovendo maior eficiência e sustentabilidade nas práticas agrícolas modernas (Soussi et al., 2024). A implementação de técnicas de AP auxilia na tomada de decisões ao longo do processo produtivo, permitindo a otimização das práticas agrícolas, o uso mais eficiente dos recursos e a redução do impacto ambiental (Kendall et al., 2022).

Uma das técnicas da AP que tem ganhado destaque nos últimos anos é a delimitação de Zonas de Manejo (ZMs). As ZMs correspondem a unidades homogêneas dentro do campo, definidas com base em características espaciais e temporais das propriedades ambientais e da cultura, como topografia, tipo de solo e condições da vegetação (Ohana-Levi et al., 2021). Uma vez estabelecidas, as ZMs servem como um guia para a amostragem de solo, permitindo a coleta de uma amostra composta por zona. Com base nos níveis de cada atributo, é possível definir manejos específicos, otimizando a aplicação de fertilizantes e corretivos de acidez do solo. Essa abordagem não apenas maximiza os retornos financeiros, mas também promove uma produção agrícola mais sustentável (Queiroz et al., 2020).

O método mais comumente utilizado para a delimitação de ZMs baseia-se em dados de produtividade de múltiplos anos. Essa abordagem é vantajosa por utilizar observações diretas da variabilidade espacial e temporal da produtividade, sem depender de suposições sobre a relação entre produtividade e atributos do solo. Por exemplo, ao utilizar-se de um sensor de condutividade elétrica aparente do solo (ECa) para delimitar ZMs, assume-se a correlação entre os valores de ECa e as propriedades do solo que impactam a produtividade das culturas (Jaynes, Colvin e Kaspar, 2005). Todavia, os mapas de produtividade estão disponíveis desde o início da década de 1990, mas sua adoção ainda se restringe a apenas 5% a 25% da área total cultivada nos Estados Unidos para culturas como trigo de inverno, algodão, sorgo e arroz e 45% para culturas do milho e soja (McFadden et al., 2023). A necessidade de manutenção e calibração dos monitores de produtividade, atividades não diretamente ligadas à colheita ou produção, dificulta a obtenção de um histórico longo e consistente de dados, essencial para garantir a

confiabilidade dos mapas de produtividade.

Neste contexto, outras abordagens vêm sendo propostas na delimitação de ZMs por meio da coleta de informações por sensores de solo ou da própria cultura como um 'sensor do solo' (Queiroz et al., 2020). A condutividade elétrica aparente (ECa) e índices de vegetação derivados de satélites, como Landsat e Sentinel-2, surgem como alternativas ao uso de mapas de produtividade na definição das ZMs. A ECa pode ser medida de forma rápida e eficiente em campos agrícolas por meio de instrumentos de indução eletromagnética, com um custo relativamente baixo quando comparado à amostragem de solo em grade de alta densidade (uma amostra por hectare) e sua subsequente análise laboratorial. Imagens ópticas multiespectrais usadas no cálculo de índices como NDVI podem ser obtidas gratuitamente por plataformas orbitais como Landsat-8 e Sentinel-2, permite a prestação de serviços remotos e ampla cobertura espacial. Diversos estudos têm demonstrado que a variabilidade espacial e temporal captada por esses sensores está frequentemente correlacionada com os atributos do solo e a variabilidade da produtividade, possibilitando seu uso na delimitação de ZMs (Ali et al., 2022; Bottega et al., 2022; da Silva et al., 2022; Moral et al., 2010).

Embora promissores, métodos que utilizam ECa e índices multiespectrais obtidos de imagens ópticas podem apresentar limitações consideráveis em determinados contextos. Informações de ECa é fortemente dependente de prestadores de serviços especializados na coleta e interpretação dos dados, cuja disponibilidade varia entre as regiões agrícolas, dificultando a implementação dessa tecnologia. Embora escalável por permitir a prestação de serviço remoto, sem a necessidade de presença física, imagens ópticas de satélites como Landsat-8 e Sentinel-2 enfrentam desafios significativos como a cobertura de nuvens, que compromete a aquisição de dados consistentes. Esse desafio é especialmente significativo em regiões tropicais, onde a cobertura de nuvens pode alcançar cerca de 66% ao longo do ano, dificultando a obtenção de séries históricas consistentes e representativas (Ju e Roy, 2008; Wei et al., 2020). Estudos indicam que a precisão das estimativas de produtividade é influenciada pelo momento da coleta das imagens ao longo do ciclo de desenvolvimento da cultura (Maresma et al., 2020; Vian et al. 2021). Portanto, a presença de nuvens é um potencial complicador que dificulta a construção de series históricas de imagens de qualidade para delimitação das ZMs. Além disso, o processo de delimitação de ZMs com base em índices ópticos multiespectrais tem como premissa culturas previamente instaladas, o que limita sua aplicação em novas áreas com potencial agrícola.

Uma linha de pesquisa promissora para mitigar as limitações dos métodos tradicionais de delimitação de ZMs é o uso de dados de Radar de Abertura Sintética (SAR). Atualmente, o programa Copernicus, da União Europeia, disponibiliza gratuitamente dados SAR por meio da missão Sentinel-1. Essa missão conta com uma constelação de dois satélites: o Sentinel-1A, lançado em 3 de abril de 2014, e o Sentinel-1B, lançado em 25 de abril de 2016. No entanto, o Sentinel-1B deixou de fornecer dados em 23 de dezembro de 2021. Os sensores dos satélites são ativos e operam na banda C (5,405 GHz) com polarização dupla (VV – Vertical Vertical e VH – Vertical Horizontal), apresentando capacidade de penetrar nuvens e adquirir imagens tanto durante o dia quanto à noite (Bioresita et al., 2019; Miles et al., 2017; Vickers et al., 2019; Xing et al., 2018). A frequência temporal das imagens varia de 6 a 12 dias, podendo ser maior em áreas com sobreposição de passagens. As imagens possuem pixels de 10 metros e resolução espacial de 20×22 metros (Torres et al., 2012).

Uma característica essencial dos dados SAR do Sentinel-1, que os diferencia das imagens ópticas, é seu comprimento de onda de aproximadamente 5 cm, permitindo a penetração no dossel das culturas agrícolas e no solo. Isso torna o sensor sensível tanto às variáveis biofísicas da vegetação, como teor de água das plantas, propriedades geométricas do dossel e rugosidade da superfície, quanto às propriedades do solo, como atributos físico-químicos e teor de água (Aubert et al., 2011; Li et al., 2022). Vários estudos demonstraram aplicações do Sentinel-1, como por exemplo: na estimativa da umidade do solo (Bousbih et al., 2017), quantificação de atributos físicos do solo (Azizi et al., 2023; Garosi et al., 2022; Mirzaeitalarposhti et al., 2022; Yang & Guo, 2019), capacidade de penetração no dossel das culturas (El Hajj et al. 2018), mapeamento de áreas com diferentes cultivos agrícolas (Bazzi et al., 2019; Tufail et al., 2022; Xun et al., 2021), monitoramento do desenvolvimento das culturas e comparação com índices ópticos como NDVI (Velooso et al. 2017) Portanto, as características dos dados SAR e os estudos citados colocam o Sentinel-1 como uma potencial alternativa aos métodos tradicionais de delimitação de ZMs.

Diante do exposto, este trabalho teve como objetivo principal avaliar o potencial de aplicação dos dados SAR na delimitação de ZMs. Buscando atender ao objetivo proposto, foram elaborados dois artigos. O primeiro artigo buscou desenvolver e comparar um método para mapear atributos do solo por meio da delimitação de ZMs utilizando dados SAR do Sentinel-1, em comparação com métodos tradicionais de amostragem de solo. O segundo artigo teve como objetivo principal avaliar a acurácia das ZMs definidas com base no índice VV/VH do Sentinel-1 na estimativa de atributos do solo, em relação a métodos convencionais que tem

por base mapas de produtividade e índice NDVI. Como objetivo secundário, foi analisada a acurácia das ZMs delimitadas pelos índices NDVI e VV/VH na previsão da produtividade média padronizada, utilizando mapas de produtividade coletados ao longo dos anos.

1.1 REFERÊNCIAS

- Ali, A., Rondelli, V., Martelli, R., Falsone, G., Lupia, F., Barbanti, L., 2022. Management Zones Delineation through Clustering Techniques Based on Soils Traits, NDVI Data, and Multiple Year Crop Yields. *Agriculture* 12, 231. <https://doi.org/10.3390/agriculture12020231>
- Aubert, M., Baghdadi, N., Zribi, M., Douaoui, A., Loumagne, C., Baup, F., El Hajj, M., Garrigues, S., 2011. Analysis of TerraSAR-X data sensitivity to bare soil moisture, roughness, composition and soil crust. *Remote Sens Environ* 115, 1801–1810. <https://doi.org/10.1016/j.rse.2011.02.021>
- Azizi, K., Garosi, Y., Ayoubi, S., Tajik, S., 2023. Integration of Sentinel-1/2 and topographic attributes to predict the spatial distribution of soil texture fractions in some agricultural soils of western Iran. *Soil Tillage Res* 229, 105681. <https://doi.org/10.1016/j.still.2023.105681>
- Bazzi, H., Baghdadi, N., El Hajj, M., Zribi, M., Minh, D.H.T., Ndikumana, E., Courault, D., Belhouchette, H., 2019. Mapping Paddy Rice Using Sentinel-1 SAR Time Series in Camargue, France. *Remote Sens (Basel)* 11, 887. <https://doi.org/10.3390/rs11070887>
- Bioresita, F., Puissant, A., Stumpf, A., Malet, J.-P., 2019. Fusion of Sentinel-1 and Sentinel-2 image time series for permanent and temporary surface water mapping. *Int J Remote Sens* 1–24. <https://doi.org/10.1080/01431161.2019.1624869>
- Bottega, E.L., Safanelli, J.L., Zeraatpisheh, M., Amado, T.J.C., Queiroz, D.M. de, Oliveira, Z.B. de, 2022. Site-Specific Management Zones Delineation Based on Apparent Soil Electrical Conductivity in Two Contrasting Fields of Southern Brazil. *Agronomy* 12, 1390. <https://doi.org/10.3390/agronomy12061390>
- Bousbih, S., Zribi, M., Lili-Chabaane, Z., Baghdadi, N., El Hajj, M., Gao, Q., Mougenot, B., 2017. Potential of Sentinel-1 Radar Data for the Assessment of Soil and Cereal Cover Parameters. *Sensors* 17, 2617. <https://doi.org/10.3390/s17112617>
- da Silva, E.E., Baio, F.H.R., Teodoro, L.P.R., Campos, C.N.S., Plaster, O.B., Teodoro, P.E., 2022. Variable-rate seeding in soybean according to soil attributes related to grain yield. *Precis Agric* 23, 35–51. <https://doi.org/10.1007/s11119-021-09826-7>

El Hajj, M., Baghdadi, N., Bazzi, H., Zribi, M., 2018. Penetration Analysis of SAR Signals in the C and L Bands for Wheat, Maize, and Grasslands. *Remote Sens (Basel)* 11, 31. <https://doi.org/10.3390/rs11010031>

Garosi, Y., Ayoubi, S., Nussbaum, M., Sheklabadi, M., Nael, M., Kimiaee, I., 2022. Use of the time series and multi-temporal features of Sentinel-1/2 satellite imagery to predict soil inorganic and organic carbon in a low-relief area with a semi-arid environment. *Int J Remote Sens* 43, 6856–6880. <https://doi.org/10.1080/01431161.2022.2147037>

Jaynes, D.B., Colvin, T.S., Kaspar, T.C., 2005. Identifying potential soybean management zones from multi-year yield data. *Comput Electron Agric* 46, 309–327. <https://doi.org/10.1016/j.compag.2004.11.011>

Ju, J., Roy, D.P., 2008. The availability of cloud-free Landsat ETM+ data over the conterminous United States and globally. *Remote Sens Environ* 112, 1196–1211. <https://doi.org/10.1016/j.rse.2007.08.011>

Kendall, H., Clark, B., Li, W., Jin, S., Jones, Glyn.D., Chen, J., Taylor, J., Li, Z., Frewer, Lynn.J., 2022. Precision agriculture technology adoption: a qualitative study of small-scale commercial “family farms” located in the North China Plain. *Precis Agric* 23, 319–351. <https://doi.org/10.1007/s11119-021-09839-2>

Li, J., Li, C., Xu, W., Feng, H., Zhao, F., Long, H., Meng, Y., Chen, W., Yang, H., Yang, G., 2022. Fusion of optical and SAR images based on deep learning to reconstruct vegetation NDVI time series in cloud-prone regions. *International Journal of Applied Earth Observation and Geoinformation* 112, 102818. <https://doi.org/10.1016/j.jag.2022.102818>

Maresma, A., Chamberlain, L., Tagarakis, A., Kharel, T., Godwin, G., Czymmek, K.J., Shields, E., Ketterings, Q.M., 2020. Accuracy of NDVI-derived corn yield predictions is impacted by time of sensing. *Comput Electron Agric* 169, 105236. <https://doi.org/10.1016/j.compag.2020.105236>

McFadden, J., Njuki, E., Griffin, T., 2023. Precision Agriculture in the Digital Era: Recent Adoption on U.S. Farms.

Miles, K.E., Willis, I.C., Benedek, C.L., Williamson, A.G., Tedesco, M., 2017. Toward Monitoring Surface and Subsurface Lakes on the Greenland Ice Sheet Using Sentinel-1 SAR and Landsat-8 OLI Imagery. *Front Earth Sci (Lausanne)* 5. <https://doi.org/10.3389/feart.2017.00058>

Mirzaeitalarposhti, R., Shafizadeh-Moghadam, H., Taghizadeh-Mehrjardi, R., Demyan, M.S., 2022. Digital Soil Texture Mapping and Spatial Transferability of Machine Learning Models Using Sentinel-1, Sentinel-2, and Terrain-Derived Covariates. *Remote Sens (Basel)* 14, 5909. <https://doi.org/10.3390/rs14235909>

Moral, F.J., Terrón, J.M., Silva, J.R.M. da, 2010. Delineation of management zones using mobile measurements of soil apparent electrical conductivity and multivariate geostatistical techniques. *Soil Tillage Res* 106, 335–343. <https://doi.org/10.1016/j.still.2009.12.002>

Ohana-Levi, N., Ben-Gal, A., Peeters, A., Termin, D., Linker, R., Baram, S., Raveh, E., Paz-Kagan, T., 2021. A comparison between spatial clustering models for determining N-fertilization management zones in orchards. *Precis Agric* 22, 99–123. <https://doi.org/10.1007/s11119-020-09731-5>

Queiroz, D.M. de, Coelho, A.L. de F., Valente, D.S.M., Schueller, J.K., 2020. Sensors Applied to Digital Agriculture: A Review. *REVISTA CIÊNCIA AGRONÔMICA* 51. <https://doi.org/10.5935/1806-6690.20200086>

Serrano, J., Mau, V., Rodrigues, R., Paixão, L., Shahidian, S., Marques da Silva, J., Paniagua, L.L., Moral, F.J., 2023. Definition and Validation of Vineyard Management Zones Based on Soil Apparent Electrical Conductivity and Altimetric Survey. *Environments* 10, 117. <https://doi.org/10.3390/environments10070117>

Soussi, A., Zero, E., Sacile, R., Trincherro, D., Fossa, M., 2024. Smart Sensors and Smart Data for Precision Agriculture: A Review. *Sensors* 24, 2647. <https://doi.org/10.3390/s24082647>

Torres, R., Snoeij, P., Geudtner, D., Bibby, D., Davidson, M., Attema, E., Potin, P., Rommen, B., Floury, N., Brown, M., Traver, I.N., Deghaye, P., Duesmann, B., Rosich, B., Miranda, N., Bruno, C., L'Abbate, M., Croci, R., Pietropaolo, A., Huchler, M., Rostan, F., 2012. GMES Sentinel-1 mission. *Remote Sens Environ* 120, 9–24. <https://doi.org/10.1016/j.rse.2011.05.028>

- Tufail, R., Ahmad, A., Javed, M.A., Ahmad, S.R., 2022. A machine learning approach for accurate crop type mapping using combined SAR and optical time series data. *Advances in Space Research* 69, 331–346. <https://doi.org/10.1016/j.asr.2021.09.019>
- Veloso, A., Mermoz, S., Bouvet, A., Le Toan, T., Planells, M., Dejoux, J.-F., Ceschia, E., 2017. Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications. *Remote Sens Environ* 199, 415–426. <https://doi.org/10.1016/j.rse.2017.07.015>
- Vian, A.L., Bredemeier, C., Drum, M.A., Pires, J.L.F., Fochesatto, E., 2021. Vegetation sensors as a tool for plant population identification and corn grain yield estimation. *Pesqui Agropecu Trop* 51. <https://doi.org/10.1590/1983-40632021v5166926>
- Vickers, H., Malnes, E., Høgda, K.-A., 2019. Long-Term Water Surface Area Monitoring and Derived Water Level Using Synthetic Aperture Radar (SAR) at Altevatn, a Medium-Sized Arctic Lake. *Remote Sens (Basel)* 11, 2780. <https://doi.org/10.3390/rs11232780>
- Wei, J., Huang, W., Li, Z., Sun, L., Zhu, X., Yuan, Q., Liu, L., Cribb, M., 2020. Cloud detection for Landsat imagery by combining the random forest and superpixels extracted via energy-driven sampling segmentation approaches. *Remote Sens Environ* 248, 112005. <https://doi.org/10.1016/j.rse.2020.112005>
- Xing, L., Tang, X., Wang, H., Fan, W., Wang, G., 2018. Monitoring monthly surface water dynamics of Dongting Lake using Sentinel-1 data at 10 m. *PeerJ* 6, e4992. <https://doi.org/10.7717/peerj.4992>
- Xun, L., Zhang, J., Cao, D., Yang, S., Yao, F., 2021. A novel cotton mapping index combining Sentinel-1 SAR and Sentinel-2 multispectral imagery. *ISPRS Journal of Photogrammetry and Remote Sensing* 181, 148–166. <https://doi.org/10.1016/j.isprsjprs.2021.08.021>
- Yang, R.-M., Guo, W.-W., 2019. Modelling of soil organic carbon and bulk density in invaded coastal wetlands using Sentinel-1 imagery. *International Journal of Applied Earth Observation and Geoinformation* 82, 101906. <https://doi.org/10.1016/j.jag.2019.101906>

2 ARTIGO I - MAPEAMENTO DE ATRIBUTOS DO SOLO COM BASE EM ZONAS DE MANEJO DELIMITADAS A PARTIR DE DADOS DE RADAR SENTINEL-1

RESUMO

A caracterização da variabilidade de atributos do solo frequentemente requer a criação de grades de amostragem densas, o que pode ser economicamente inviável. Uma possível solução é realizar amostragens direcionadas com base em dados previamente coletados. O objetivo desta pesquisa foi desenvolver um método para mapear atributos do solo com base em Zonas de Manejo (ZMs) delimitadas a partir de dados de radar Sentinel-1. O estudo foi conduzido em dois campos de produção de grãos, e a variabilidade dos atributos do solo em cada campo foi caracterizada por meio de amostragem em grade. Para cada campo, imagens do Sentinel-1 foram utilizadas para criar o perfil temporal de seis índices com base nas bandas de retroespalhamento VV (vertical-vertical) e VH (vertical-horizontal) no período de janeiro de 2018 a março de 2023. Para delimitar as ZMs, todos os índices e as bandas VV e VH foram analisados individualmente usando duas abordagens: a primeira aplicou o algoritmo de agrupamento *fuzzy k-means* às séries temporais dos índices, e a segunda utilizou o algoritmo de *deep learning autoencoders* para reduzir a dimensionalidade das séries temporais, seguido pela aplicação do *fuzzy k-means*. A melhor combinação de índice e abordagem de delimitação de ZMs foi comparada com 4 métodos de mapeamento de atributos do solo: convencional (amostra única composta), grade uniforme de alta densidade (uma amostra por hectare), células retangulares (uma amostra composta por células retangulares de 5 a 10 hectares) e células aleatórias (uma amostra composta por células de diferentes formatos e tamanhos). O método de validação cruzada deixe-um-de-fora foi utilizado para avaliar o desempenho de cada método de amostragem. Os resultados demonstraram que a combinação do índice VV/VH com *autoencoders* para a delimitação de ZMs proporcionou estimativas mais precisas dos atributos do solo em comparação com as demais estratégias e índices analisados. Embora o método de grade uniforme de alta densidade tenha apresentado a maior acurácia geral nas estimativas dos atributos do solo, a estratégia com base no índice VV/VH e *autoencoders* destacou-se ao superar o método convencional e, em muitos casos, o método de células e células aleatórias.

Palavras-chave: Agricultura de precisão, Sensoriamento Remoto, Amostragem de solo, Radar de Abertura Sintética, Aprendizado Profundo.

ABSTRACT

The characterization of soil attribute variability often requires the creation of dense sampling grids, which can be economically unfeasible. A potential solution lies in performing targeted sampling based on previously collected data. This research aimed to develop a method for mapping soil attributes based on Management Zones (MZ) delineated from Sentinel-1 radar data. The study was conducted in two grain production fields, and the variability of soil attributes in each field was characterized through grid-based sampling. For each field, Sentinel-1 images were used to generate time profiles for six indices derived from VV (vertical-vertical) and VH (vertical-horizontal) backscatter bands over the period from January 2018 to March 2023. To delineate MZ, all indices and the VV and VH backscatter bands were individually analyzed using two approaches: the first applied the fuzzy k-means clustering algorithm to the time series of the indices, and the second utilized the deep learning algorithm autoencoders to reduce the dimensionality of the time series, followed by the application of fuzzy k-means clustering. The best combination of index and MZ delineation approach was compared with four soil attribute mapping methods: conventional (single composite sample), high-density uniform grid (one sample per hectare), rectangular cells (composite samples from rectangular cells of 5 to 10 hectares), and random cells (composite samples from cells of varying shapes and sizes). The “leave-one-out” cross-validation method was employed to evaluate the performance of each sampling strategy. The results demonstrated that the combination of the VV/VH index with autoencoders for MZ delineation provided more accurate estimates of soil attributes compared to other strategies and indices analyzed. While the high-density uniform grid method achieved the highest overall accuracy in soil attribute estimation, the approach based on the VV/VH index and autoencoders outperformed the conventional method and, in many cases, the rectangular and random cell methods.

Keywords: Precision Agriculture, Remote Sensing, Soil Sampling, Synthetic Aperture Radar, Deep Learning.

2.1 INTRODUÇÃO

As informações sobre a variabilidade espacial e temporal dos atributos do solo desempenham um papel crucial no desenvolvimento de estratégias eficazes de manejo do solo. Ao analisar esses dados, os agricultores podem adotar as cultivares mais adequadas e as densidades populacionais de plantas mais apropriadas para cada ponto específico dentro da área de produção. Isso, por sua vez, facilita a determinação precisa das quantidades necessárias de fertilizantes e corretivos de acidez do solo, não apenas para maximizar os retornos financeiros, mas também para promover uma produção mais sustentável (Queiroz et al. 2020).

No entanto, desenvolver uma estratégia eficaz para coletar dados que caracterizem a variabilidade espacial e temporal dos atributos do solo é uma tarefa complexa e desafiadora. Pesquisas têm destacado a importância de estabelecer grades de amostragem densas, sendo realizada, no mínimo, a coleta de uma amostra por hectare, para capturar adequadamente a variabilidade dos atributos do solo (Franzen e Peck 1995; Lauzon et al. 2005; Lawrence et al. 2020). Webster e Oliver (1992) demonstraram que variogramas usados para inferir atributos do solo em pontos não amostrados são pouco confiáveis quando modelados a partir de banco de dados com menos de 100 pontos de coleta, resultando em estimativas imprecisas com margens de erro significativas. Portanto, a amostragem em grid pode fornecer uma base precisa para a aplicação em taxa variável, mas os custos e a necessidade de mão de obra, especialmente em áreas extensas com alta variabilidade, indicam que outras abordagens podem ser mais econômicas (Fleming et al. 2000).

Para compreender a variabilidade espacial e temporal dos atributos do solo sem a necessidade de estabelecer grades de amostragem densas, pesquisas têm demonstrado o potencial do uso de sensores de solo ou da própria cultura como um 'sensor do solo' (Queiroz et al., 2020). Sensores de condutividade elétrica aparente do solo, mapas de produtividade e índices de reflectância do dossel podem fornecer mapas com diferentes padrões de variabilidade espacial e temporal e serem utilizados para estabelecer áreas homogêneas, conhecidas como Zonas de Manejo (ZMs) (Bottega et al. 2022; Brock et al. 2005; Damian et al. 2020; Jaynes et al. 2005; Peralta et al. 2013; Valente et al. 2012). Dentro de cada ZMs, assume-se uma baixa variabilidade dos atributos do solo, recomendando-se a coleta de uma única amostra composta. Com base nos níveis específicos desses atributos, estabelece-se manejos específicos para cada ZMs. Essa estratégia reduz os custos com amostragem de solo se comparado a grades de amostragem densas ao mesmo tempo em que promove melhor a distribuição de práticas de

manejo (cultivares, densidade de plantas, fertilizantes) se comparado ao método convencional de amostragem do solo, onde se determina somente um único nível de atributos e consequentemente de manejo para toda área.

Embora o desenvolvimento de ZMs por meio desses métodos represente um avanço na agricultura de precisão, sua adoção entre os agricultores ainda é limitada. Essa limitação deve-se, em grande parte, à dificuldade de acesso a mapas históricos confiáveis de produtividade, dados de condutividade elétrica e séries temporais de imagens de satélite multiespectrais com alta resolução temporal. Por exemplo, os mapas de produtividade estão disponíveis desde o início da década de 1990, mas sua adoção ainda se restringe a apenas 5% a 25% da área total cultivada nos Estados Unidos para culturas como trigo de inverno, algodão, sorgo e arroz e 45% para culturas do milho e soja (McFadden et al., 2023). A condutividade elétrica aparente do solo, se apresenta como uma alternativa atraente pois pode ser medida para campos de forma rápida e fácil usando instrumentos de indução eletromagnética. Todavia, este tipo de levantamento de informação é fortemente dependente de prestadores de serviços especializados na coleta e interpretação dos dados, cuja disponibilidade varia entre as regiões agrícolas, dificultando a implementação dessa tecnologia.

O uso de imagens ópticas multiespectrais, disponibilizadas gratuitamente por plataformas orbitais como Landsat-8 e Sentinel-2, permite a prestação de serviços remotos e ampla cobertura espacial. No entanto, sua aplicação enfrenta desafios significativos, como a cobertura de nuvens, que compromete a aquisição de dados consistentes. Esse problema é particularmente crítico em regiões tropicais, onde a cobertura média anual de nuvens pode atingir aproximadamente 66%, dificultando a construção de séries históricas representativas (Ju e Roy, 2008; Wei et al., 2020). Portanto, para ampliar a adoção das ZM pelos agricultores, é essencial desenvolver métodos alternativos que permitam caracterizar a variabilidade espacial e temporal dos atributos do solo de forma eficiente, com menor custo por unidade de área e ampla cobertura espacial.

Uma linha de pesquisa promissora para a caracterização da variabilidade espacial e temporal dos atributos do solo por meio de ZMs é o uso de dados de Radar de Abertura Sintética (SAR). A missão Sentinel-1, do programa *Copernicus* da União Europeia, atualmente composta pelo sensor Sentinel-1A, disponibiliza gratuitamente imagens SAR com resolução espacial de 20×22 metros e resolução temporal de 12 dias (Torres et al., 2012). Equipado com um sensor ativo SAR de banda C, operando a uma frequência central de 5,405 GHz e com polarização

dupla (Vertical-Vertical e Vertical-Horizontal), esse satélite possui a capacidade de penetrar nuvens e adquirir imagens tanto durante o dia quanto à noite (Bioresita et al., 2019; Miles et al., 2017; Vickers et al., 2019; Xing et al., 2018). Além disso, suas ondas eletromagnéticas de maior comprimento podem atravessar as camadas superficiais da vegetação e, em alguns casos, alcançar camadas mais profundas do solo. No contexto agrícola, os dados de retroespalhamento SAR têm sido utilizados, isoladamente ou em combinação com dados multiespectrais, para diversas aplicações, incluindo a estimativa de umidade do solo (Balenzano et al., 2021; Chaudhary et al., 2022; Rossini et al., 2021), a avaliação de atributos físicos do solo (Azizi et al., 2023; Garosi et al., 2022; Mirzaeitalarposhti et al., 2022; Yang & Guo, 2019) e a estimativa de índices multiespectrais, como o Índice de Vegetação por Diferença Normalizada (NDVI) (Frison et al., 2018; Kaushik et al., 2021; Veloso et al., 2017), entre outras aplicações.

Portanto, as propriedades mencionadas anteriormente destacam o potencial das imagens SAR do Sentinel-1 como uma fonte de dados rica em informações espaço-temporais, tornando-as promissoras para o mapeamento de atributos do solo e a delimitação de ZMs. É possível criar perfis temporais de retroespalhamento com dupla polarização VV (vertical-vertical) e VH (vertical-horizontal) a partir de dados SAR, complementados pela determinação de índices SAR específicos. Esses perfis temporais podem ser analisados por meio de técnicas de classificação não supervisionada para identificar regiões com respostas de retroespalhamento semelhantes, potencialmente associadas a variações nos atributos do solo. Portanto, o objetivo deste estudo foi desenvolver um método para mapear atributos do solo por meio da delimitação de ZMs utilizando dados SAR fornecidos pelo Sentinel-1.

2.2 MATERIAL E MÉTODOS

2.2.1 Área de Estudo

O presente estudo foi conduzido em dois campos comerciais de produção de grãos (Campo A e Campo B) que apresentam diferentes características de textura do solo (Fig. 1). O Campo A cobre uma área de 117 hectares e está localizado no município de Sinop, Mato Grosso, Brasil (11°08'20" S e 56°19'18" W). O Campo B abrange uma área de 106 hectares e está situado no município de Chapadão do Céu, Goiás, Brasil (18°20'10" S e 52°37'12" W). De acordo com o Sistema Brasileiro de Classificação de Solos, o Campo A é identificado como um Latossolo Vermelho-Amarelo Distrófico, enquanto o Campo B é classificado como um Latossolo Vermelho Distrófico (Embrapa, 2013). Para a coleta de amostras de solo, foi adotado o método de amostragem em pontos de grade densa com espaçamento aproximado de 100

metros. O Campo A foi representado por 113 amostras, e o Campo B por 104 amostras, conforme ilustrado na Figura 1.

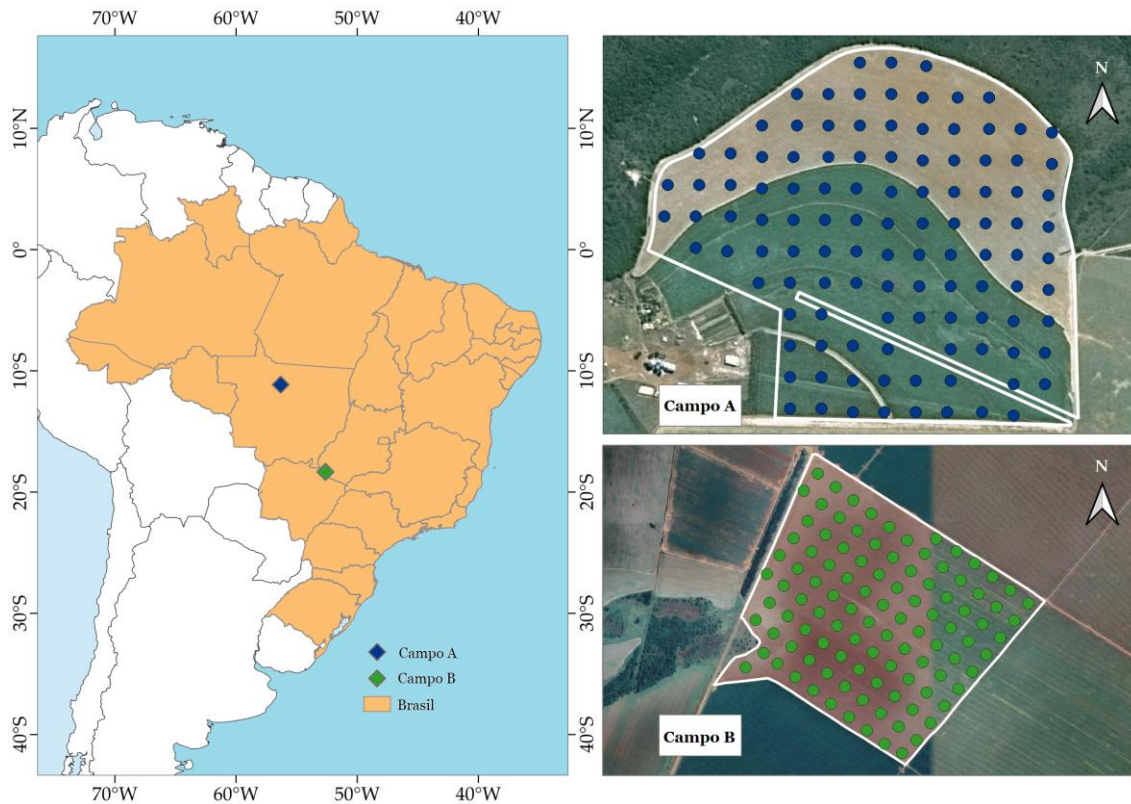


Figura 1. Localização dos campos de estudo (Campo A e Campo B) no Brasil.

2.2.2 Conjunto de dados e pré-processamento Sentinel-1

Os dados SAR utilizados neste estudo foram adquiridos gratuitamente a partir de dois sensores (Sentinel-1A e Sentinel-1B) do programa Copernicus da União Europeia. A missão Sentinel-1 fornece dados SAR globais na banda C (frequência central de 5,405 GHz) com polarização dupla (VV e VH). A resolução temporal varia de 6 a 12 dias em diferentes regiões do globo, embora possa ser maior em alguns casos devido à sobreposição de passagens do sensor. Neste estudo, foi utilizada a coleção *Sentinel-1* no *Google Earth Engine*, que compreende imagens dos sensores Sentinel-1A e 1B no formato *Ground Range Detected* (GRD), processadas com a ferramenta Sentinel-1 toolbox para gerar um produto calibrado e ortoretificado. Todas as imagens foram adquiridas em órbitas descendentes utilizando o modo de faixa *Interferometric Wide* (IW) e polarização dupla (VV e VH). Elas possuem um espaçamento de pixels de 10 metros, mas uma resolução espacial de 20×22 metros (Torres et al. 2012).

Os passos de pré-processamento dos dados SAR incluíram a remoção de ruídos nas bordas, aplicação de filtro *speckle*, normalização radiométrica do terreno e conversão do coeficiente de retroespalhamento para decibéis (dB) (Fig. 2). O ruído nas bordas das imagens é resultado do processo de conversão de aquisições do formato GRD para IW, sendo indesejado pois limita sua plena utilização em diversas aplicações (Stasolla e Neyt 2018). O fenômeno *speckle*, comum em imagens SAR devido à interferência de ondas de radar refletidas por superfícies menores que a resolução do radar, foi tratado por meio de filtragem multitemporal (Quegan e Jiong Jiong Yu 2001). O filtro Lee, 3x3 (Lee et al., 1999), foi aplicado com uma estrutura de filtragem multitemporal de 10 imagens. A normalização radiométrica do terreno corrige variações no sinal recebido devido à inclinação do terreno. Para isso, utilizou-se o modelo de elevação digital da missão *Shuttle Radar Topography Mission* (SRTM) com resolução de 1 segundo de arco (~30 m) (Farr et al., 2007), derivando valores de elevação, inclinação e orientação para a normalização. Por fim, como último passo do pré-processamento, o coeficiente radiométrico de retroespalhamento corrigido pelo terreno é convertido para decibéis por meio de uma transformação logarítmica. A Tabela 1 resume os parâmetros e especificações para aquisição e pré-processamento das imagens. Os dados foram pré-processados utilizando o Google Earth Engine (GEE) (Gorelick et al., 2017). Todos os códigos GEE para o pré-processamento de dados Sentinel-1 foram fornecidos por Mullissa et al. (2021) e estão disponíveis em https://github.com/adugnag/gee_s1_ard.

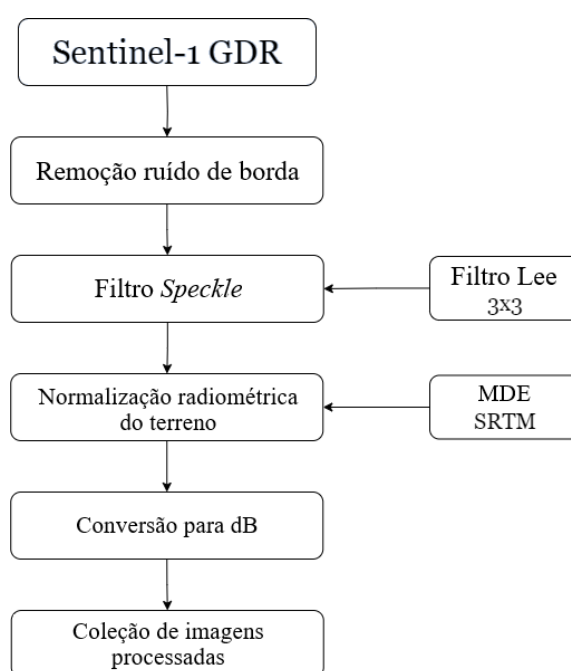


Figura 2. Fluxograma do pré-processamento dos dados Sentinel-1 *Ground Range Detected* (GRD) utilizando o Modelo Digital de Elevação (MDE) da Missão *Shuttle Radar Topography Mission* (SRTM).

Tabela 1. Especificações dos dados SAR do Sentinel-1 usados neste estudo.

Parâmetros	Especificações
Passada Satélite	Descendente
Polarização	Vertical-Vertical (VV)
	Vertical-Horizontal (VH)
Filtro <i>Speckle</i>	Filtro Lee - 3x3 (Lee et al., 1999)
Estrutura do filtro <i>Speckle</i>	Multitemporal – 10 imagens
Modelo de elevação digital	NASA SRTM 30m (Farr et al., 2007)

2.2.3 Geração de perfis temporais e índices SAR

Após o pré-processamento, cada imagem SAR foi convertida em uma tabela e armazenada para gerar perfis temporais de retroespalhamento. Para cada campo analisado, foi estabelecida uma grade de quadriláteros de 40m x 40m. Em cada imagem, os valores médios dos pixels dentro desses quadriláteros foram calculados, construindo assim os perfis temporais de retroespalhamento para as bandas VV e VH. Este método ajuda a minimizar possíveis ruídos residuais nas imagens e reduz a carga computacional necessária para análises subsequentes. Com base nesses perfis, seis índices foram calculados utilizando dados do Sentinel-1, conforme detalhado na Tabela 2. Cada série temporal de retroespalhamento das bandas VV e VH, bem como os índices para cada quadrilátero, foram padronizados usando a normalização *z-score*. Esse processo ajusta os dados para que cada conjunto tenha média 0 e desvio padrão 1. Para evitar problemas de colinearidade entre os índices, foi calculada a correlação de Pearson (r) entre eles. Com base nessa análise, apenas os índices que apresentaram menor colinearidade ($r < 0,95$) foram incluídos, garantindo assim a independência e relevância de cada índice escolhido para a definição das ZM.

Tabela 2. Os índices SAR utilizados neste estudo para delimitar zonas de manejo.

Nome completo	Nome abreviado	Equação	Fonte
Polarimetric Radar Vegetation Index	PRVI	$\left(1 - \frac{VV}{VH + VV}\right) * VH$	(Chang et al., 2018) https://custom-scripts.sentinel-hub.com/custom-scripts/sentinel-1/radar_vegetation_index/#
Sentinel-1 Radar Vegetation Index	RV14S1	$\sqrt{\frac{VV}{VH + VV}} * \frac{4 * VH}{VH + VV}$	(Trudel et al., 2012)
Radar Vegetation Index	RVI	$\frac{4 * VH}{VH + VV}$	(Filgueiras et al., 2019)
Normalized Ratio Procedure Between Bands	NRPB	$\frac{VH - VV}{VH + VV}$	(Veloso et al., 2017)
VV VH Ratio	VV_VH	$\frac{VV}{VH}$	(Frison et al., 2018)
VH VV Ratio	VH_VV	$\frac{VH}{VV}$	-
VH Backscattering	VH	VH	-
VV Backscattering	VV	VV	-

VV: Polarização Vertical-Vertical; VH: Polarização Vertical-Horizontal

Para compreender a variabilidade sazonal dos índices SAR, foram utilizados dados de precipitação do sistema NASA-POWER (<https://power.larc.nasa.gov>), considerando que os dados de radar são sensíveis à umidade do solo (Balenzano et al., 2021; Chaudhary et al., 2022; Rossini et al., 2021). Esse sistema foi desenvolvido para fornecer informações meteorológicas diretamente aplicáveis a campos como arquitetura, geração de energia e agrometeorologia. Ele compila informações de diversas fontes de dados, incluindo dados derivados de grades, para oferecer uma visão abrangente das condições climáticas e meteorológicas (Maldonado et al., 2019).

2.2.4 Delimitação de zonas de manejo usando dados SAR

Para delimitar as ZM, todos os índices SAR foram analisados individualmente, e duas abordagens foram propostas. A primeira abordagem (Abordagem 1) envolveu a aplicação direta do algoritmo de agrupamento *fuzzy k-means* (Bezdek et al., 1984) nas séries temporais dos índices SAR. Na segunda abordagem (Abordagem 2), foi implementado um método de aprendizado de máquina conhecido como *autoencoders* para reduzir a dimensionalidade das séries temporais. Os *autoencoders* são um tipo de rede neural frequentemente usada em tarefas de aprendizado de máquina não supervisionado, como extração de características (Hoang e

Kang, 2019). A arquitetura básica de um *autoencoder* é dividida em três partes: codificador (*encoder*), camada de redução e decodificador (*decoder*) (Figura 3). O codificador recebe os dados de entrada (neste caso, índices SAR) e os comprime em uma representação de dimensão reduzida (camada de redução). O decodificador, então, utiliza essa representação comprimida para tentar reconstruir os dados originais. Esse processo é realizado durante o treinamento da rede *autoencoder*. Assim, após o treinamento, a camada de redução foi utilizada como entrada para o algoritmo *fuzzy k-means* para realizar o agrupamento das séries temporais dos dados SAR e, conseqüentemente, definir as ZMs. Todo o processo de delineamento das ZMs foi implementado em Python (versão 3.10).




Figura 3. Representação de uma estrutura básica de *autoencoder*.

Para definição da arquitetura e parâmetros de treinamento, foi implementado um processo de validação cruzada *k*- grupos, com $k=5$, visando a definição dos hiperparâmetros mais adequados. A seleção do modelo final baseou-se no menor erro quadrático médio obtido durante o processo de validação. A arquitetura e os parâmetros de treinamento selecionados estão detalhados nas Tabelas 3 e 4. A função de ativação ReLU ($\sigma(x) = \max(0, x)$) foi utilizada nas camadas ocultas devido à sua simplicidade computacional e às vantagens que oferece em termos de convergência e estabilidade do treinamento. Na camada de saída, foi aplicada uma função de ativação linear ($\sigma(x) = x$) para permitir a reconstrução das séries temporais normalizadas pelo *z-score*, que podem assumir valores tanto negativos quanto positivos. A Figura 4 apresenta as curvas de perda durante os processos de treinamento e validação, expressas como erro quadrático médio (RMSE), ao longo de 200 épocas. A redução progressiva dos valores de perda, seguida de estabilização, indica que o *autoencoder* minimizou

efetivamente o erro de reconstrução, sem indícios de sobreajuste. Esses resultados demonstram a capacidade de generalização da arquitetura selecionada e a adequação dos parâmetros de treinamento definidos.

Tabela 3. Arquitetura *autoencoder* proposta para extração de características.

Camadas	Tipo	Neurônios	Função de ativação
Entrada (SAR)	-	Nº de imagens SAR para cada campo	-
Camada codificador	Totalmente Conectada	32	<i>Relu</i>
Camada de redução	Totalmente Conectada	6	<i>Relu</i>
Camada decodificador	Totalmente Conectada	32	<i>Relu</i>
Camada de saída	Totalmente Conectada	Nº de imagens SAR para cada campo	Sigmoide

Tabela 4. Parâmetros utilizados para treinar a arquitetura do *autoencoder*.

Parâmetros	Valor
Número de épocas	200
Função de otimização	Adam
Taxa de aprendizado	0.0001
Tamanho de Lote	1
Função de perda	Erro quadrático médio
Regularização	L2 (lambda = 0.01)

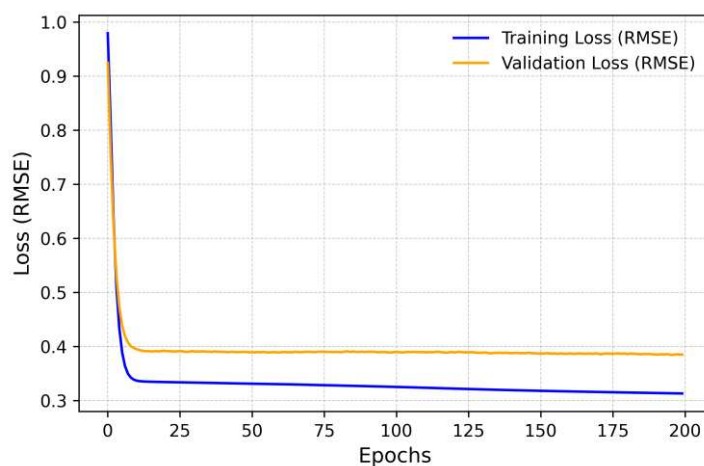


Figura 4. Curvas de perda durante o treinamento e validação do *autoencoder*, expressas como erro quadrático médio (RMSE) ao longo de 200 épocas. Observa-se uma queda acentuada nas épocas iniciais, seguida de estabilização, indicando um bom ajuste do modelo sem sinais de sobreajuste.

As simulações de definição das ZM foram realizadas considerando o número de zonas (k-grupos) igual a três para ambas as abordagens e campos. Após o agrupamento, as ferramentas de geoprocessamento do QGIS foram utilizadas para refinamentos. Grupos com área menor que 3 hectares foram integrados aos clusters contíguos maiores, enquanto clusters

maiores que 3 hectares, mas geograficamente desconectados e compartilhando o mesmo rótulo, foram considerados como grupos distintos.

2.2.5 Validação das zonas de manejos geradas a partir de dados SAR

Os métodos mais comuns de amostragem de solo incluem o método convencional de amostragem de solo (CONV), o método de amostragem de solo baseado em células (CEL), o método de amostragem de solo em grade uniforme (GRID-1) e o método de amostragem de solo baseado em ZM. O método CONV envolve a coleta de várias amostras para formar uma única amostra composta, considerada representativa de todo o campo. No presente estudo, o método CONV foi considerado como a média de todas as amostras coletadas. Por outro lado, o método CEL dividiu a área em células (polígonos de 5 a 10 hectares), garantindo a presença de pelo menos quatro amostras do GRID-1 em cada célula. A estimativa de atributos em cada célula foi calculada como a média das amostras coletadas dentro de cada célula. Um quinto método de comparação foi proposto, no qual as células são criadas aleatoriamente, chamado de método de amostragem de solo baseado em células aleatórias (CEL-RND) (Figura 5). O número de células aleatórias foi definido para coincidir com o número de ZMs estabelecidas pelo método baseado em dados SAR. No total, 1000 cenários de células aleatórias foram gerados para cada área de estudo. O tamanho mínimo de cada célula aleatória foi de 4 hectares, garantindo a presença de pelo menos quatro amostras de solo por célula. As células aleatórias foram geradas usando um script Python com base em diagramas de Voronoi, propostos por Georgy Voronoi (Voronoi, 1908), e os atributos do solo dentro de cada célula foram estimados pela média das amostras coletadas em cada célula.

$$\gamma^*(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} (z(x_i) - z(x_i + h))^2 \quad (1)$$

em que $\gamma^*(h)$ é o valor da semivariância experimental no intervalo de distância h ; $z(x_i)$ é o valor da amostra medida nos pontos de amostragem x_i , onde existe dados em x_i and $x_i + h$; $N(h)$ é o número total de pares de amostras dentro do intervalo de distância h .

Durante a adaptação dos modelos teóricos aos semivariogramas experimentais, foram determinados coeficientes que descrevem o efeito pepita (C_0), platô ($C_0 + C$), platô parcial (C) e alcance (A). Os modelos testados para adaptação incluíram os modelos esférico, exponencial, gaussiano e linear, sendo selecionados com base na maximização do coeficiente de determinação (R^2), na minimização da soma dos resíduos quadráticos e na maximização do coeficiente de correlação obtido por validação cruzada. Essas métricas são utilizadas para avaliar o quão bem o modelo ajustado corresponde aos dados experimentais. O Índice de Dependência Espacial (SDI) foi analisado usando a razão $C_0/(C_0 + C)$, e os intervalos propostos por Cambardella et al. (1994) foram empregados para classificar a dependência espacial em três categorias: dependência forte ($SDI < 25\%$), dependência moderada ($25\% \leq SDI < 75\%$) e dependência fraca ($SDI \geq 75\%$). Os semivariogramas dos atributos químicos e físicos do solo foram modelados utilizando o SmartMap (Pereira et al., 2022) Versão 1.4, um plugin de código aberto desenvolvido para o QGIS.

Ao comparar os valores estimados dos atributos do solo obtidos pelos métodos CONV, CEL, MZ, GRID-1 e CEL-RND com os valores amostrados em cada ponto correspondente, foi calculado o Erro Quadrático Médio (RMSE). Essa análise foi conduzida individualmente para cada campo de estudo, seguindo a metodologia estabelecida na equação (2):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2} \quad (2)$$

em que: \hat{x}_i representa o valor estimado do atributo de solo no ponto i ; x_i o valor observado do atributo de solo no ponto i ; e n , o número de pontos amostrados.

Para comparar as ZM definidas a partir dos dados SAR com os outros métodos de amostragem de solo utilizados neste estudo, foi selecionada a combinação de abordagem (1 ou 2) e índice SAR que resultou no menor RMSE. Após essa seleção, a média de cada atributo foi calculada para cada zona, e os atributos foram comparados usando o teste F (com nível de significância de $p\text{-valor} < 0,05$). Os valores de RMSE do método de amostragem ZM para cada campo foram comparados com os valores resultantes dos outros métodos de amostragem avaliados neste estudo. Para avaliar o método CEL-RND, foi quantificada, entre os 1000 cenários gerados, a frequência com que o método ZM apresentou um RMSE maior do que o

CEL-RND. Em seguida, foi calculada a porcentagem desses cenários em que o método MZ teve desempenho inferior, em termos de RMSE, em comparação com o método CEL-RND.

2.3 RESULTADOS

2.3.1 Análise exploratória do conjunto de dados SAR

A Tabela 5 apresenta um resumo das imagens SAR coletadas entre 1º de janeiro de 2018 e 31 de março de 2023 para os dois campos em estudo. Embora o satélite Sentinel-1 possua uma resolução temporal de 12 dias para a América do Sul, diferentes resoluções temporais foram observadas nos campos, o que pode ser atribuído à sobreposição de sensores. O Campo A apresentou uma resolução temporal mais alta, com registros do satélite a cada 6,0 dias. Por outro lado, no Campo B, menos imagens foram coletadas, resultando em uma resolução temporal de 7,4 dias.

Tabela 5. Número de imagens disponíveis e resolução temporal para cada campo, no período de 1 de janeiro de 2018 à 31 de março de 2023.

Campo	Número de imagens	Resolução temporal
A	319	6,0 dias
B	266	7,4 dias

A Figura 6 apresenta o coeficiente de correlação de pearson (r) estimado entre os valores de retroespalhamento VV e VH e os índices SAR. As correlações obtidas foram significativas, com valores de p iguais a zero. Os índices RVI, NRPB, VH/VV e VV/VH apresentaram altas correlações entre si, assim como PRVI e VH, com valores acima de 0,95. Por outro lado, o índice RVI4SI apresentou o menor nível de correlação com os demais índices. Com base nesses resultados, quatro índices (VV, VH, VV/VH, RVI4SI) foram selecionados para a continuidade do estudo.



Figura 6. Correlação de Pearson entre os valores de retroespalhamento VV e VH e os índices SAR obtidos nos campos A e B.

As médias mensais da série temporal para os coeficientes de retroespalhamento VV e VH, assim como para os índices VV/VH e RVI4SI, foram plotadas para ambos os campos em cada ano (Figura 7). Considerando que a disponibilidade de dados se estendeu apenas até março de 2023, a análise gráfica foi restrita ao período de 2018 a 2022. As séries temporais dos índices calculados exibiram tendências sazonais. Com exceção do índice VV/VH, observou-se um aumento entre setembro e dezembro, seguido por uma queda em fevereiro. Esse comportamento coincide com o período de aumento do acumulado mensal de precipitação (Figura 8), sugerindo uma possível relação entre maior umidade do solo ou crescimento da vegetação e níveis elevados de retroespalhamento. De fevereiro a março, embora a precipitação tenda a permanecer relativamente constante, há um novo aumento no retroespalhamento, provavelmente devido ao crescimento da vegetação de segunda safra. Posteriormente, de maio a setembro, houve uma diminuição nos índices SAR, em consonância com a redução do acumulado mensal de precipitação e da biomassa das culturas. Para o índice VV/VH, houve um aumento entre janeiro e fevereiro, seguido por uma diminuição de fevereiro a abril, exceto nos anos de 2019 e 2021. Além disso, apenas para o índice VV/VH, foi registrado um aumento nos valores entre abril e agosto.




Figura 7. Gráficos de dispersão com linhas suavizadas dos coeficientes de retrospalhamento e índices SAR para os campos A e B ao longo dos meses, cobrindo o período de 1 de janeiro de 2018 a 31 de dezembro de 2022.

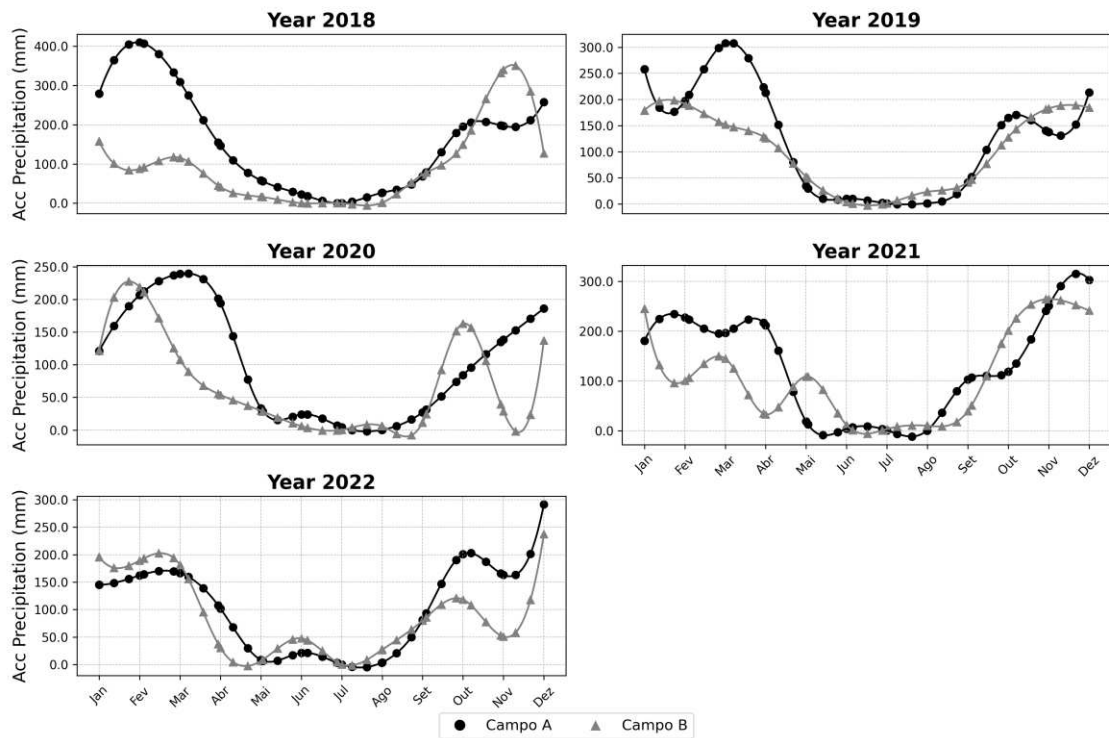


Figura 8. Gráficos de dispersão com linhas de tendência suavizadas da precipitação acumulada mensal para os campos A e B, utilizando dados do NASA POWER, em subplots anuais de janeiro de 2018 a dezembro de 2022.

2.3.2 Análise exploratória do conjunto de dados de solo

A Tabela 6 apresenta as estatísticas descritivas de nove atributos do solo coletados no GRID-1 para os Campos A e B. A maioria dos coeficientes de variação (CV) dos campos estava na faixa moderada ($12 \leq CV < 60\%$), de acordo com Warrick e Nielsen (1980). Quanto à curtose, a maioria dos valores foi inferior a 3, exceto para pH, cálcio (Ca^{2+}) e saturação por bases (V) no Campo A, indicando uma distribuição mais achatada em comparação com uma distribuição normal.

Tabela 6. Resumo das estatísticas descritivas das propriedades do solo medidas na área de estudo.

Campo	Atributo do solo	Unidade	Média	Mínimo	Máximo	STD	Cv (%)	Curtose
A	ARG	g/kg	35,65	16,3	62	11,91	33	-0,7
	pH	-	6,11	5,76	7,78	0,28	5	13,21
	P	mg/dm ³	17,91	3,4	56,6	10,4	58	0,87
	K ⁺	mg/dm ³	86,24	25	199	36,72	43	1,64
	Ca ²⁺	cmolc/dm ³	2,55	0,99	5,82	0,7	28	4,8
	Mg ²⁺	cmolc/dm ³	0,84	0,43	1,68	0,22	26	1,19
	C	cmolc/dm ³	1,43	0,47	2,78	0,45	31	0,82
	V	%	51,65	36,7	97	8,95	17	6,48
B	H ⁺ + Al ³⁺	cmolc/dm ³	3,28	0,2	5,2	0,81	25	1,52
	ARG	g/kg	37	19	58,3	7,71	21	0,37
	pH	-	6,35	5,81	6,91	0,21	3	-0,04
	P	mg/dm ³	13,75	2,5	30,1	6,16	45	0,31
	K ⁺	mg/dm ³	55,55	26	120	19,43	35	0,89
	Ca ²⁺	cmolc/dm ³	3,3	2,14	5,23	0,61	18	0,25
	Mg ²⁺	cmolc/dm ³	1,25	0,72	2,08	0,29	24	-0,51
	C	cmolc/dm ³	1,58	0,87	2,86	0,32	2	1,73
V	%	62,29	49,5	74,6	5,46	9	-0,29	
H ⁺ + Al ³⁺	cmolc/dm ³	2,87	1,2	4,4	0,72	25	-0,52	

ARG: Argila; pH: Acidez ativa na água; P: Fósforo; K⁺: Potássio; Ca²⁺: Cálcio; Mg²⁺: Magnésio; C: Carbono orgânico do Solo; V Saturação por bases; H⁺ + Al³⁺: Acidez potencial; STD: Desvio padrão; Cv: coeficiente de variação (%).

A análise dos semivariogramas experimentais no GRID-1 confirmou a variabilidade espacial dos atributos do solo para ambos os campos (Tabela 7). Ao analisar o índice de dependência espacial (SDI), constatou-se que o teor de argila (CLA) e o carbono orgânico do solo (C) no Campo A, assim como CLA e acidez potencial (H⁺ + Al³⁺) no Campo B, apresentaram valores de SDI inferiores a 25%, indicando alta dependência espacial (Cambardella et al., 1994). Todos os outros elementos, exceto o fósforo (P) em ambos os campos, exibiram valores de SDI entre 25% e 75%, o que indica dependência espacial moderada (Cambardella et al., 1994). As Figuras 9 e 10 mostram os mapas construídos por krigagem ordinária após o ajuste dos semivariogramas. Nos Campos A e B, os mapas de CLA e C, bem como os de Ca²⁺ e magnésio (Mg²⁺), respectivamente, exibem semelhanças visuais

que indicam altas correlações entre esses atributos do solo.

Tabela 7. Parâmetros do modelo teórico ajustados à semivariância empírica dos atributos do solo para o Campo A e Campo B.

Campo	Atributo do solo	Model	Alcance (m)	C0	C0 + C	R2	SDI (%)
A	ARG	Gaussiano	697,85	14,72	198,50	0,99	7,42
	pH	Linear com patamar	370,64	0,022	0,036	0,47	61,11
	P	Esférico	396,95	45,27	96,66	0,74	46,83
	K ⁺	Linear com patamar	642,51	286,77	1012,68	0,99	28,32
	Ca ²⁺	Linear com patamar	419,14	0,12	0,36	0,79	33,33
	Mg ²⁺	Linear com patamar	458,12	0,02	0,04	0,83	50,00
	C	Linear com patamar	472,85	0,04	0,17	0,97	23,52
	V (%)	Linear com patamar	347,48	28,78	48,47	0,59	59,37
	H ⁺ + Al ³⁺	Linear com patamar	379,13	0,24	0,57	0,67	42,11
B	ARG	Esférico	401,31	3,77	58,51	0,97	6,44
	pH	Linear	557,85	0,02	0,04	0,948	50,00
	P	Linear com patamar	320,92	26,97	33,60	0,29	80,26
	K ⁺	Exponencial	788,23	160,36	341,29	0,92	46,99
	Ca ²⁺	Linear	552,69	0,13	0,30	0,98	43,33
	Mg ²⁺	Linear	559,91	0,03	0,08	0,99	37,50
	C	Linear	557,18	0,03	0,09	0,99	33,33
	V	Linear com patamar	585,78	23,10	31,00	0,96	74,19
	H ⁺ + Al ³⁺	Linear	569,48	0,09	0,53	0,98	16,98

ARG: Argila; pH: Acidez ativa na água; P: Fósforo; K⁺: Potássio; Ca²⁺: Calcio; Mg²⁺: Magnésio; C: Carbono orgânico do Solo; V Saturação por bases; H⁺ + Al³⁺: Acidez potencial; C0: Efeito Pepita; C0 + C: Platô; R²: Coeficiente de determinação; SDI (%): Índice de Dependência Especial.

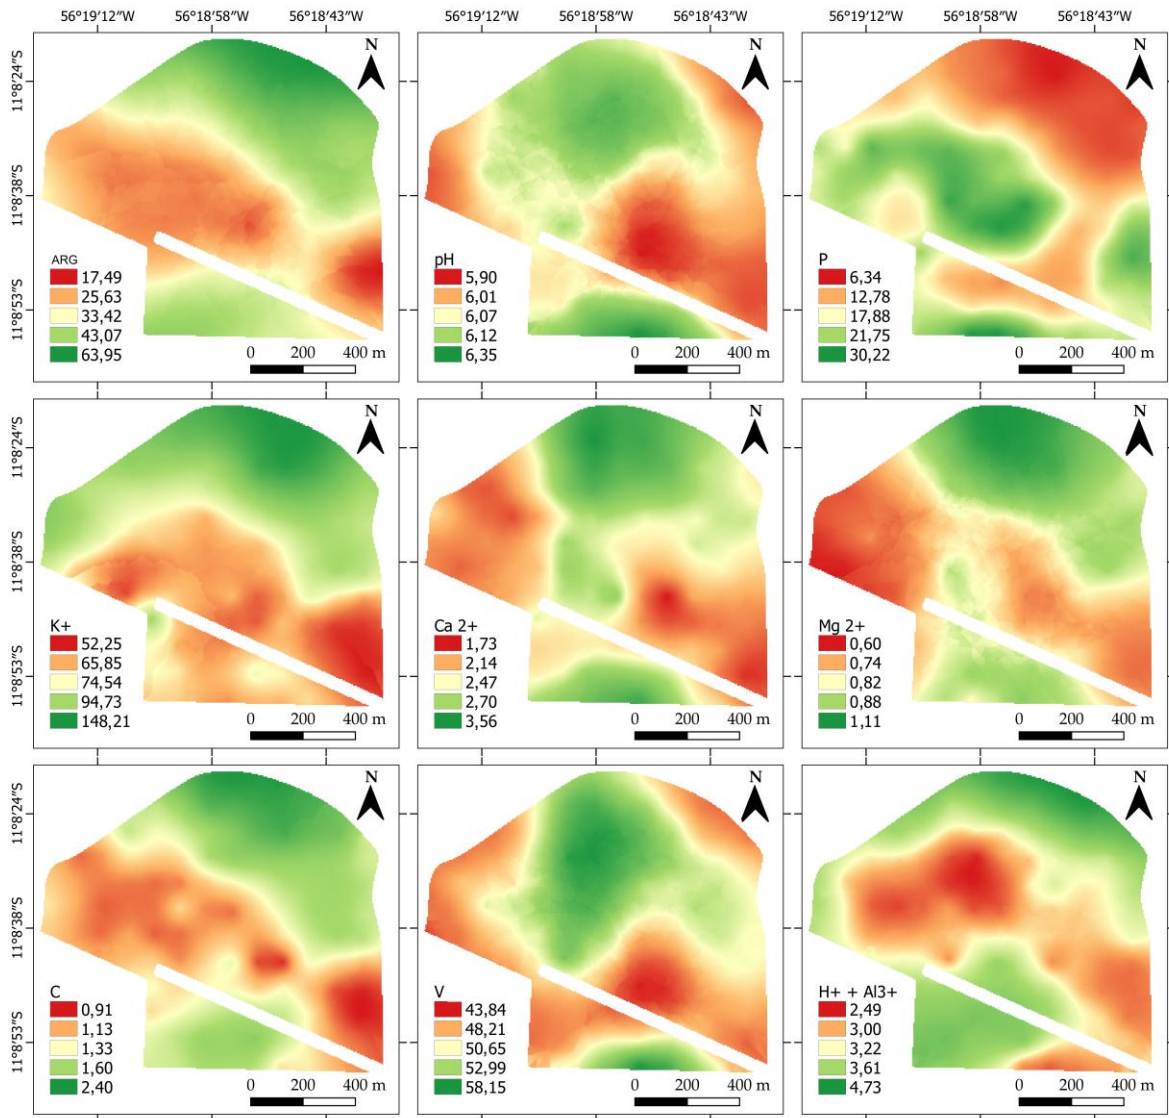


Figura 9. Mapas dos atributos do solo interpolados por krigagem ordinária para o Campo A utilizando o GRID-1. ARG: Argila (%); pH: Acidez ativa na água; P: Fósforo (mg dm⁻³); K⁺: Potássio (mg dm⁻³); Ca²⁺: Cálcio (cmolc dm⁻³); Mg²⁺: Magnésio (cmolc dm⁻³); C: Carbono orgânico do Solo (cmolc dm⁻³); V Saturação por bases (%); H⁺ + Al³⁺: Acidez potencial (cmolc dm⁻³).

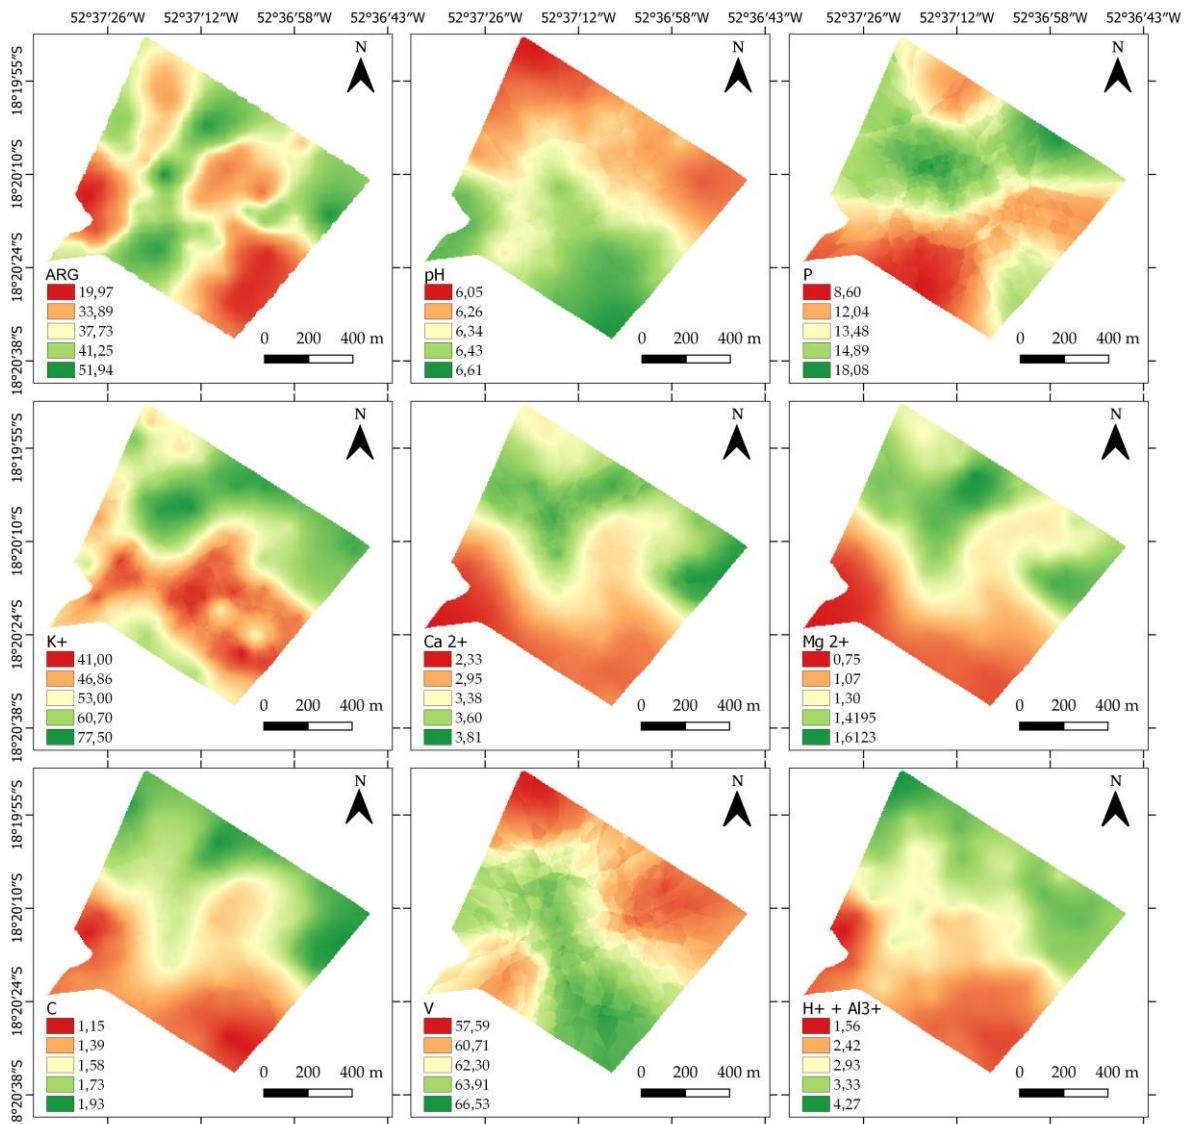


Figura 10. Mapas dos atributos do solo interpolados por krigagem ordinária para o Campo B utilizando o GRID-1. ARG: Argila (%); pH: Acidez ativa na água; P: Fósforo (mg dm^{-3}); K⁺: Potássio (mg dm^{-3}); Ca²⁺: Cálcio (cmolc dm^{-3}); Mg²⁺: Magnésio (cmolc dm^{-3}); C: Carbono orgânico do Solo (cmolc dm^{-3}); V Saturação por bases (%); H⁺ + Al³⁺: Acidez potencial (cmolc dm^{-3}).

2.3.3 Delimitação de Zonas de Manejo com SAR

Em relação ao design e à quantidade de ZM, variações visuais foram observadas dependendo do índice SAR utilizado e do método adotado (Figura 11). Essas variações em tamanho, forma e número de ZM tornam-se ainda mais perceptíveis ao contrastar os métodos propostos. O número total de ZM na Abordagem 1 superou o da Abordagem 2. No caso do Campo B, o número de ZM de acordo com a Abordagem 1 foi 2, inferior ao valor inicialmente estipulado de 3. Esse resultado ocorreu porque alguns clusters criados pelo algoritmo *fuzzy k-means* não apresentaram associações significativas com os pontos de dados ou exibiram um

grau de pertinência extremamente baixos em relação a todos os pontos para um cluster específico. Além disso, o índice RVI4SI resultou em clusters excessivamente fragmentados em comparação com os outros algoritmos avaliados. Devido a essa fragmentação, considerou-se inadequado utilizar este índice para a criação de ZM no Campo B. Por isso, seus resultados não foram considerados neste estudo.

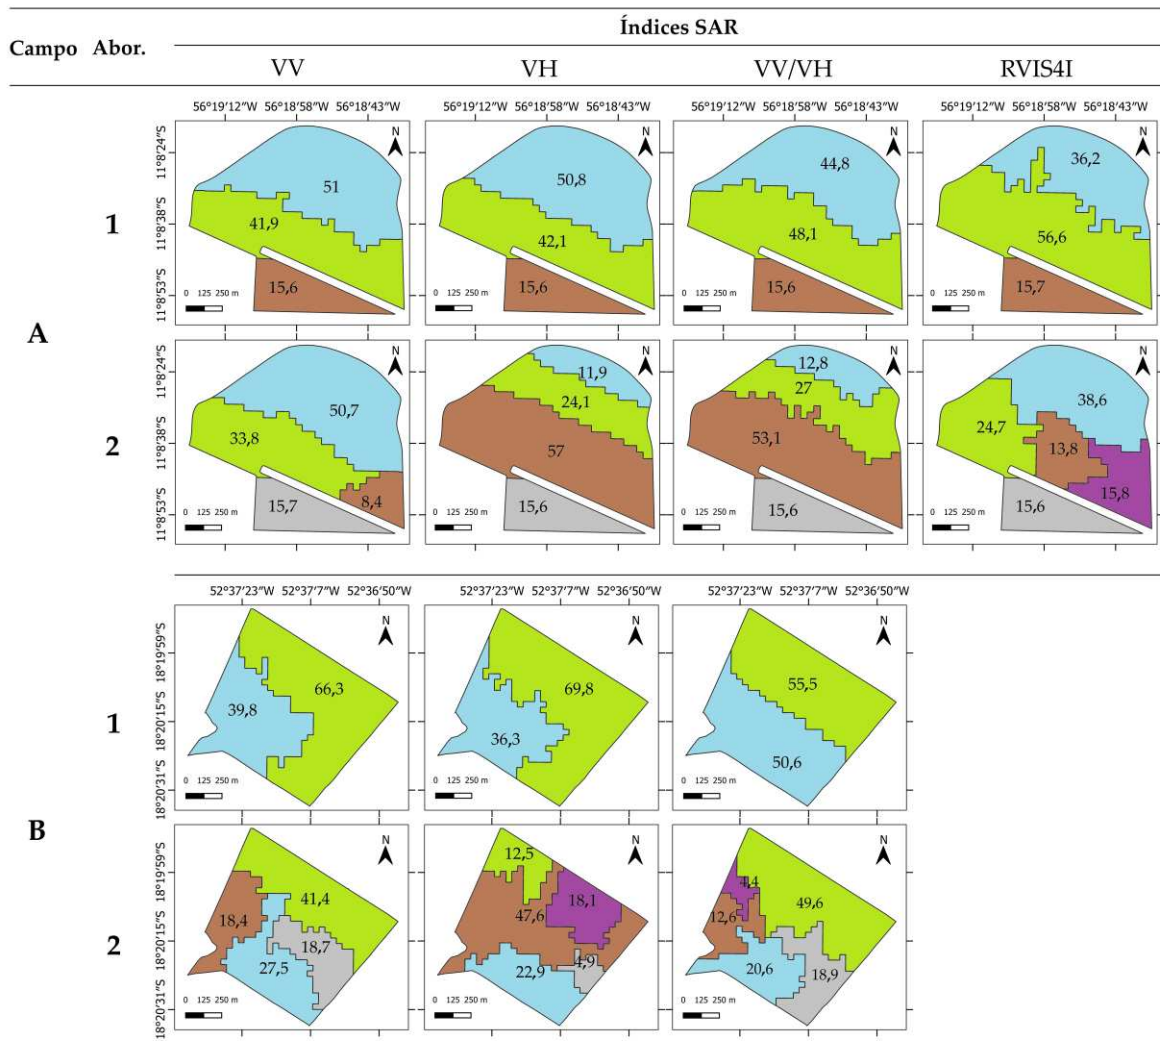


Figura 11. Zonas de Manejo derivadas de índices SAR para ambos os talhões (A e B), utilizando duas abordagens (Abor. 1 e Abor. 2). (A) Resultados do Talhão A utilizando quatro índices SAR (VV, VH, VV/VH, RVI4SI) sob as Abordagens 1 e 2 (linhas 1 e 2, respectivamente). (B) Resultados do Talhão B utilizando três índices SAR (VV, VH, VV/VH) sob as Abordagens 1 e 2 (linhas 1 e 2, respectivamente). As Abordagens 1 e 2 referem-se, respectivamente, ao agrupamento aplicado diretamente às séries temporais dos dados SAR e às suas representações reduzidas obtidas por meio de autoencoders. As cores são utilizadas apenas para distinguir os limites das zonas de manejo.

A Tabela 8 apresenta os valores de RMSE obtidos por meio de LOOCV, representando a precisão das estimativas de atributos do solo para os Campos A e B utilizando as Abordagens

1 e 2 com o método ZM. Na avaliação dos erros associados à estimativa de atributos do solo, o índice VV/VH destacou-se consistentemente, alcançando os menores valores de RMSE em comparação com os outros índices. Por exemplo, no Campo A, ao estimar o atributo teor de argila utilizando a Abordagem 2, a banda de retroespalhamento VV registrou um RMSE de 8,33, enquanto o índice VV/VH apresentou um RMSE significativamente menor, de 5,74. Ao analisar as duas abordagens, observa-se que a Abordagem 2 apresenta uma vantagem em termos de precisão sobre a Abordagem 1, especialmente ao adotar a razão VV/VH para a estimativa de atributos do solo. Em todos os campos estudados, os atributos CLA, P, Ca²⁺ e C registraram valores menores de RMSE com a Abordagem 2 ao utilizar o índice VV/VH.

Tabela 8. RMSE das abordagens A e B para os campos A e B relacionados aos coeficientes de retroespalhamento VV e VH, e aos índices SAR VV/VH e RVI.

Campo	Abordagem	Atributo do solo	VV	VH	VV/VH	RVI4SI
A	Abordagem 1	ARG	8,99	9,01	7,82	7,67
		pH	0,27	0,27	0,27	0,27
		P	10,08	10,18	9,74	9,42
		K ⁺	31,63	31,73	29,73	29,21
		Ca ²⁺	0,66	0,65	0,65	0,65
		Mg ²⁺	0,2	0,2	0,19	0,2
		C	0,38	0,38	0,36	0,35
		V	8,99	8,93	9,04	9,09
	H ⁺ + Al ³⁺	0,82	0,83	0,81	0,8	
	Abordagem 2	ARG	8,33	6,34	5,74	7,82
		pH	0,27	0,27	0,27	0,27
		P	9,98	9,81	9,67	10,02
		K ⁺	31,28	24,87	23,7	29,47
		Ca ²⁺	0,65	0,64	0,64	0,63
Mg ²⁺		0,19	0,19	0,19	0,19	
C		0,36	0,3	0,27	0,35	
V		9	9,08	9,05	8,99	
H ⁺ + Al ³⁺	0,82	0,75	0,75	0,83		
B	Abordagem 1	ARG	7,77	7,81	7,48	-
		pH	0,21	0,21	0,19	-
		P	6,24	6,23	6,21	-
		K ⁺	19,24	18,79	18,28	-
		Ca ²⁺	0,61	0,6	0,55	-
		Mg ²⁺	0,29	0,29	0,26	-
		C	0,32	0,31	0,29	-
		V	5,51	5,52	5,3	-
	H ⁺ + Al ³⁺	0,7	0,7	0,56	-	
	Abordagem 2	ARG	7,31	7,8	6,53	-
		pH	0,19	0,19	0,2	-
		P	6,14	6,26	6,08	-
		K ⁺	18,25	19,03	19,22	-
		Ca ²⁺	0,57	0,57	0,53	-
Mg ²⁺		0,27	0,27	0,25	-	
C		0,29	0,29	0,28	-	
V		5,31	5,31	5,52	-	
H ⁺ + Al ³⁺	0,58	0,59	0,58	-		

ARG: Argila; pH: Acidez ativa na água; P: Fósforo; K⁺: Potássio; Ca²⁺: Cálcio; Mg²⁺: Magnésio; C: Carbono orgânico do Solo; V Saturação por bases; H⁺ + Al³⁺: Acidez potencial.

Os resultados indicaram diferenças significativas nos valores dos atributos do solo entre as ZM delimitadas pela Abordagem 2 e o índice SAR VV/VH, que apresentou o menor RMSE (Tabela 9). Pelo menos uma média de cada atributo do solo nas ZM diferiu estatisticamente com um valor de $p < 0,05$, exceto para o atributo V em ambos os campos. Para o Campo A, a ZM3 foi caracterizada como a zona com os maiores valores médios de CLA, potássio (K⁺), Ca²⁺, Mg²⁺, C e acidez potencial (H⁺ + Al³⁺), enquanto a ZM2 apresentou os menores valores. Para o Campo B, a ZM2 foi caracterizada como a zona com os menores valores médios de CLA, P, Ca²⁺, Mg²⁺ e C.

Tabela 9. Análise de variância univariada dos atributos do solo para as zonas de manejo delimitadas pela Abordagem 2 e pelo índice SAR VV/VH do campo A e B.

Campo	Zonas de Manejo	Número de amostras	Atributos do solo									
			ARG	pH	P	K ⁺	Ca ²⁺	Mg ²⁺	C	V	H ⁺ + Al ³⁺	
A	ZM1	20	38,11	6,29	19,81	73,35	2,91	0,87	1,47	54,40	3,34	
	ZM2	52	25,97	6,02	21,41	67,38	2,20	0,72	1,12	49,84	3,04	
	ZM3	12	58,23	6,05	8,48	160,50	3,11	1,09	2,29	50,03	4,33	
	ZM4	28	42,18	6,15	14,13	98,64	2,70	0,93	1,59	53,75	3,23	
	Análise de variância	<i>F</i> -Valor	128,5	5,25	7,98	57,93	11,57	17,78	69,34	2,03	10,15	
		Prob > <i>F</i>	0	0,002	0	0	0	0	0	0,11	0	
B	ZM1	49	39,30	6,26	14,54	62,08	3,6	1,41	1,73	60,94	3,31	
	ZM2	4	40,58	6,28	16,7	55	3,8	1,54	1,75	63,32	3,18	
	ZM3	14	33,75	6,42	14,61	52,5	3,16	1,15	1,48	63,9	2,56	
	ZM4	20	40,58	6,42	9,63	48,85	2,98	1,06	1,44	62,92	2,45	
	ZM5	17	28,01	6,51	14,92	47,24	2,81	1,03	1,33	63,91	2,25	
	Análise de variância	<i>F</i> -Valor	12,80	6,89	3,13	3,07	11,21	13,86	9,14	1,57	16,57	
	Prob > <i>F</i>	0	0	0,02	0,02	0	0	0	0,19	0		

ARG: Argila; pH: Acidez ativa na água; P: Fósforo; K⁺: Potássio; Ca²⁺: Cálcio; Mg²⁺: Magnésio; C: Carbono orgânico do Solo; V Saturação por bases; H⁺ + Al³⁺: Acidez potencial. ARG em %; P e K⁺ em mg/dm³; Ca²⁺, Mg²⁺, C e H⁺ + Al³⁺ em cmolc/dm³.

A Figura 12 apresenta uma comparação entre o erro (RMSE) obtido pelo método ZM utilizando a Abordagem 2 e o índice SAR VV/VH, e o erro gerado a partir de 1000 diferentes cenários CEL-RND. O valor indicado em cada barra representa a porcentagem de vezes em que o método ZM, baseado em dados SAR, apresentou um erro maior do que o método de células aleatórias. Portanto, quanto menor o valor percentual exibido na barra, melhor o desempenho do método ZM em comparação com o CEL-RND. Valores iguais ou superiores a 50% indicam que as ZM não contribuem para a representatividade da variabilidade dos atributos do solo em relação a um processo aleatório. Conforme observado, para a maioria dos atributos do solo em ambos os campos, o RMSE resultante do método de amostragem CEL-RND foi maior do que o RMSE obtido pelo método de amostragem ZM, resultando em valores abaixo de 50% (Figura

11). No Campo A, os atributos com o menor percentual de erro (menos de 5%) são CLA, K^+ , C, $H^+ + Al^{3+}$ e pH. Isso indica que o método ZM teve um bom desempenho para esses atributos neste campo. Por outro lado, o atributo V apresentou um percentual de erro significativamente maior, de 43%, indicando que o método ZM pode não ser tão eficiente para este atributo específico. No Campo B, o atributo CLA apresentou um percentual de erro relativamente baixo, em torno de 3,9%. Por outro lado, os atributos pH, K^+ e V apresentaram erros consideravelmente mais elevados, em torno de 48%, 72% e 77%, respectivamente.

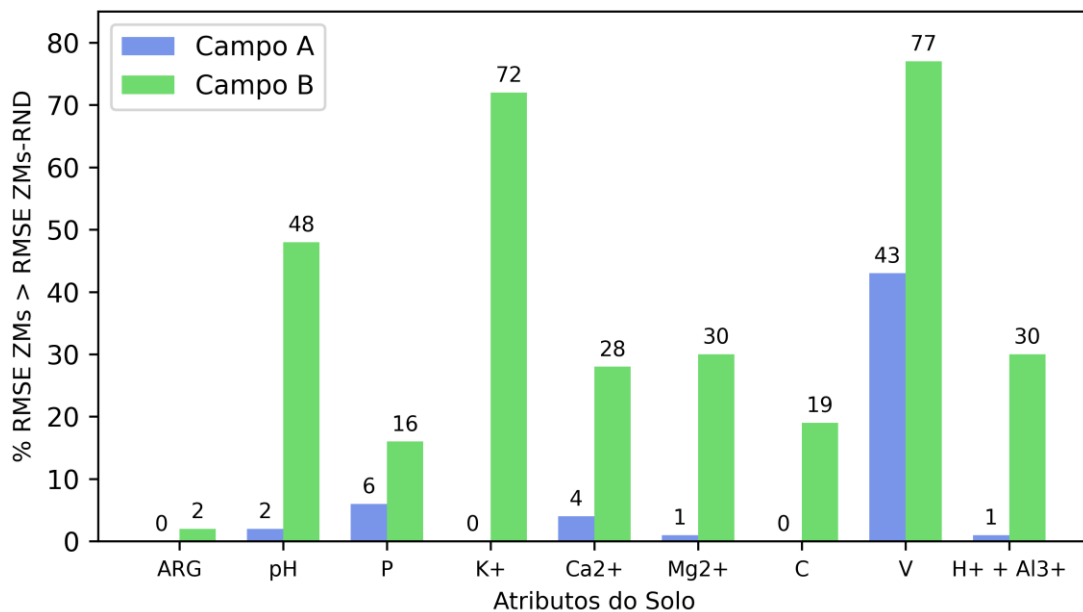


Fig.

Figura 12. Valor percentual em que o RMSE do método Zonas de Manejo (ZMs) delimitadas pela Abordagem 2 e pelo índice SAR VV/VH foi maior que o RMSE gerado pelos 1000 cenários de células aleatórias (CEL-RND). ARG: Argila; pH: Acidez ativa na água; P: Fósforo; K^+ : Potássio; Ca^{2+} : Cálcio; Mg^{2+} : Magnésio; C: Carbono orgânico do Solo; V Saturação por bases; $H^+ + Al^{3+}$: Acidez potencial.

2.3.4 Comparação de Métodos de Amostragem de Solo

A Tabela 10 destaca os valores de RMSE obtidos por meio da validação cruzada LOOCV, demonstrando a precisão das estimativas de atributos do solo nos Campos A e B utilizando diferentes estratégias de amostragem: GRID-1, CONV, CEL e ZM utilizando a Abordagem 2 e o índice SAR VV/VH. O método GRID-1 registrou os menores valores de RMSE em ambos os campos, indicando superioridade na precisão das estimativas de atributos do solo. Em ambos os campos, o método CONV destacou-se pelos maiores valores de RMSE, indicando menor precisão nas estimativas. As ZM delimitadas a partir de dados SAR mostraram

superioridade em comparação aos métodos CONV e CEL no Campo A. No Campo B, as ZM superaram o método convencional.

Tabela 10. RMSE dos métodos de amostragem GRID-1, CONV, CEL e ZM delimitadas pela Abordagem 2 e pelo índice SAR VV/VH para os atributos do solo para os campos A e B.

Campo	Atributo do solo	GRID-1	CONV	CEL	ZM
Campo A	ARG	3,49	11,97	6,24	5,74
	pH	0,22	0,28	0,29	0,27
	P	6,72	10,44	10,23	9,67
	K	18,59	36,88	25,32	23,7
	Ca ²⁺	0,43	0,71	0,64	0,64
	Mg ²⁺	0,15	0,22	0,2	0,19
	C	0,17	0,45	0,31	0,27
	V	7,07	8,99	9,34	9,05
	H+AL	0,55	0,82	0,84	0,75
Campo B	ARG	1,45	7,75	6,35	6,53
	pH	0,14	0,21	0,2	0,2
	P	5,24	6,19	6,95	6,08
	K	12,69	19,52	20,12	19,22
	Ca ²⁺	0,36	0,61	0,46	0,53
	Mg ²⁺	0,14	0,3	0,2	0,25
	C	0,19	0,32	0,26	0,28
	V	4,63	5,48	5,66	5,52
	H+AL	0,26	0,72	0,54	0,58

ARG: Argila; pH: Acidez ativa na água; P: Fósforo; K⁺: Potássio; Ca²⁺: Cálcio; Mg²⁺: Magnésio; C: Carbono orgânico do Solo; V Saturação por bases; H⁺ + Al³⁺: Acidez potencial. ARG em g/kg; P e K⁺ em mg/dm³; Ca²⁺, Mg²⁺, C e H⁺ + Al³⁺ em emolc/dm³.

2.4 DISCUSSÃO

No contexto do sensoriamento remoto de campos agrícolas dedicados à produção de grãos, séries temporais de retroespalhamento SAR foram utilizadas para definir zonas de manejo. Embora o satélite Sentinel-1 possua uma resolução temporal de 12 dias para a América do Sul, foi observado um menor intervalo de revisita do sensor, possivelmente devido à sobreposição de sensores durante as passagens do satélite. Uma maior resolução temporal aprimora a detecção de tendências e padrões espaço-temporais. Além disso, permite o uso de períodos mais curtos para consulta, processamento e análise dos padrões de variabilidade espacial e temporal dos campos. Isso proporciona uma abordagem mais precisa para compreender e interpretar as mudanças no retroespalhamento registradas ao longo do tempo.

A análise da relação entre os valores de retroespalhamento VV e VH e os índices SAR revelou que certos índices apresentam fortes correlações, indicando possíveis redundâncias. Esse achado está alinhado com o estudo de Pelta et al. (2022), que identificou que os índices RVI, NRPB, VH/VV e VV/VH apresentam alta correlação mútua, com valores superiores a 0,95 ou inferiores a -0,95. Além disso, tanto em nossa análise quanto no estudo citado, o índice

RVI4SI exibiu a menor correlação em comparação com os outros índices. Assim, esses resultados sugerem que, independentemente dos campos agrícolas estudados, a relação entre os valores de retroespalhamento VV e VH e os índices SAR tende a seguir padrões semelhantes.

De setembro a dezembro, foi observado um aumento nos índices VV e VH. Esse crescimento pode estar relacionado ao retorno da estação chuvosa, que aumenta o teor de umidade do solo. De fato, durante esse mesmo período, há um aumento no acumulado mensal de precipitação, o que eleva os níveis de umidade do solo. Além disso, a época de plantio das culturas agrícolas, que ocorre entre setembro e outubro, também influencia esse fenômeno, pois o aumento da biomassa intensifica o retroespalhamento do sinal (El Hajj et al., 2018). No entanto, no mesmo período, o índice VV/VH apresentou uma queda. Segundo estudos, a banda de polarização VV é particularmente mais sensível à umidade do solo em comparação à banda VH, o que levou à redução do índice VV/VH durante esse período (Amazirh et al., 2018; Bousbih et al., 2017). Além disso, estudos demonstraram que a polarização VH é sensível tanto à rugosidade da superfície quanto ao volume da vegetação devido ao efeito de despolarização causado pelo espalhamento volumétrico da vegetação (Gao et al., 2017). Assim, embora os valores de retroespalhamento VH tendam a aumentar com a umidade do solo, a degradação dos resíduos de culturas no solo durante esse período tem um efeito contrário sobre esse aumento. Isso ocorre porque a degradação dos resíduos reduz a rugosidade da superfície, consequentemente diminuindo a intensidade do retroespalhamento VH.

Entre dezembro e janeiro, observa-se uma estabilização nos valores de retroespalhamento VV e VH. Esse fenômeno ocorre porque, com a biomassa da cultura totalmente desenvolvida, há um efeito de atenuação do dossel sobre as bandas, reduzindo sua sensibilidade à variação de umidade do solo. Bousbih et al. (2017) mostraram que a sensibilidade das bandas VV e VH à variação de umidade do solo diminui com o aumento do crescimento da cobertura vegetal (NDVI) e é mais pronunciada na polarização VV do que na polarização cruzada VH. El Hajj et al. (2018) demonstraram que a banda C de polarização VV penetra no dossel de milho mesmo quando a cultura está no pico de sua biomassa ($NDVI > 0,7$). No entanto, a penetração foi limitada em culturas de trigo e pastagens. Portanto, durante o desenvolvimento do dossel da cultura, a vegetação pode se tornar o principal componente que contribui para o espalhamento volumétrico do sinal retroespalhado, enquanto a influência do solo pode se tornar secundária.

Entre fevereiro e março, durante a senescência das culturas, foi observada uma diminuição nos valores de retroespalhamento VV e VH, acompanhada por um aumento no índice VV/VH. No entanto, em abril, esse índice apresentou uma queda. Esse comportamento pode ser atribuído à queda das folhas, que impacta mais intensamente a banda VV, levando à redução no índice VV/VH. Conforme o segundo ciclo de cultivo avança, a intensidade da banda VV volta a aumentar, resultando em um novo crescimento no índice VV/VH. Soudani et al. (2021) demonstraram que a redução no índice VV/VH ocorre mais tarde do que a do NDVI e do LAI (Índice de Área Foliar), e é quase sincronizada com a queda das folhas. O NDVI diminui antes da queda das folhas devido ao amarelamento e escurecimento das folhas, que caracterizam a senescência. Assim, o índice VV/VH parece depender muito mais da quantidade de elementos de espalhamento (folhas, galhos) e de sua geometria do que de índices multiespectrais como o NDVI.

Os campos de produção comercial de grãos utilizados neste estudo exibiram alta variabilidade em quase todos os atributos do solo. Quanto à curtose, a maioria dos valores foi classificada como tendo uma distribuição platicúrtica, caracterizada por ser mais achatada do que uma distribuição normal, com caudas mais leves. A variabilidade espacial do solo surge da combinação de fatores como processos de formação do solo, fenômenos meteorológicos e intervenções antrópicas. Os processos de formação do solo resultam em interações complexas entre mecanismos biológicos, físicos e químicos (Moral et al., 2010; Peralta e Costa, 2013). Para que qualquer técnica de amostragem de solo seja eficaz em comparações, é essencial a presença de variabilidade em seus atributos. São essas nuances que os métodos de amostragem buscam capturar, delineando subáreas dentro dos campos que compartilhem características semelhantes. Quanto maior a variabilidade desses atributos, mais densa precisa ser a amostragem do solo para representar adequadamente a área. Isso ressalta a importância de introduzir métodos como ZM, que permitem representar essa variabilidade a um custo reduzido.

A avaliação dos semivariogramas experimentais no GRID-1, para ambos os campos, destacou a dependência espacial dos atributos do solo. O SDI, que relaciona o efeito pepita ao patamar para quantificar a dependência espacial desses atributos, foi inferior a 75% para a maioria dos atributos. Isso indica uma forte dependência espacial (inferior a 25%) e uma dependência espacial moderada (entre 25% e 75%), conforme sugerido por Cambardella et al. (1994). Nesse contexto, a krigagem se destaca como um método excelente para interpolação e estimativa de atributos do solo em locais não amostrados.

As bandas de retroespalhamento VV e VH, juntamente com os índices VV/VH e RVI4SI, apresentaram variações no tamanho, forma e número de ZM quando submetidas às abordagens 1 e 2. A Abordagem 2, que aplica agrupamento em características extraídas de séries temporais SAR por meio de *autoencoders*, tendeu a gerar mais ZM em ambos os campos em comparação com a Abordagem 1, que realiza o agrupamento diretamente nas séries temporais. Os *autoencoders* pertencem a uma classe específica de redes neurais artificiais profundas. Eles são projetados para comprimir uma entrada em uma representação mais compacta e, em seguida, reverter essa compressão, buscando que a entrada reconstruída se assemelhe o máximo possível à original (Bank et al., 2023). As características extraídas pelo *autoencoder*, representadas pela parte compactada, podem capturar nuances e padrões nos dados que a representação bruta não consegue. Isso leva a uma segmentação mais detalhada dos campos, resultando em um número maior de ZM. Outro ponto a ser considerado é que as imagens SAR são caracterizadas por altos níveis de ruído (Schmidt et al., 2020). Assim, o uso de características extraídas por *autoencoders* representa uma versão menos ruidosa dos dados originais, pois o processo de aprendizado da arquitetura extrai padrões que explicam o comportamento temporal do retroespalhamento. Esse fator pode resultar em um agrupamento mais preciso e no aumento do número de ZM.

O índice VV/VH, combinado com a Abordagem 2 baseada em *autoencoders*, tende a apresentar valores menores de RMSE para a estimativa de atributos do solo utilizando a estratégia LOOCV. Dessa forma, foi capaz de produzir ZM com maior precisão em comparação a outros índices SAR. A integração das informações das bandas de retroespalhamento VV e VH demonstrou desempenho superior em relação ao uso isolado de cada banda em diversas aplicações (Bazzi et al., 2019; Lasko et al., 2018). Esse fenômeno é justificado pelo fato de que a razão VV/VH minimiza erros do sistema de aquisição e fornece indicações mais consistentes ao longo do tempo do que o retroespalhamento isolado de VH ou VV, conforme apontado por Veloso et al. (2017). Além disso, certos estudos indicam que o índice VV/VH apresenta maior correlação com o NDVI em estágios fenológicos específicos das culturas. Isso sugere que esse índice ajuda a compreender não apenas a variabilidade espacial da umidade do solo, mas também a estrutura do dossel e a biomassa da cultura — aspectos cruciais para a definição de ZM (Soudani et al., 2021).

Ao analisar as ZM derivadas do índice VV/VH utilizando *autoencoders* em ambos os campos, foi observada uma distinção estatística em pelo menos uma média de cada atributo do solo originado das ZM, exceto para o atributo V. Apesar da alta variabilidade de argila na

região, diferenças estatísticas também foram detectadas em atributos temporalmente instáveis, como Ca^{2+} , Mg^{2+} , K^+ , entre outros. A capacidade das plantas de acessar esses atributos é fortemente influenciada pela habilidade do solo em reter água em seus macros e microporos. Assim, a sensibilidade dos dados SAR à umidade do solo, como evidenciado em vários estudos, é crucial para identificar a variabilidade dos macros e micronutrientes presentes no solo (Balenzano et al., 2021; Bousbih et al., 2017; Dabrowska-Zielinska et al., 2018).

Ao analisar as ZM geradas pelo índice VV/VH utilizando *autoencoders* em comparação com as ZM criadas aleatoriamente (ZM - RND), destacou-se o potencial do índice SAR para delimitar ZM. Apenas para os atributos do solo K^+ e V no Campo A foi observado que, em mais de 50% dos cenários, o RMSE das ZM - RND foi menor do que o RMSE estimado pelas ZM. O melhor desempenho do índice VV/VH em relação às ZM - RND foi observado para o teor de argila em ambos os campos. A fração de argila do solo está intrinsecamente ligada à retenção de água (Ismail e Ozawa, 2007). Assim, a sensibilidade dos dados SAR à umidade do solo pode ser uma das explicações para a alta correlação observada entre as ZM e a variabilidade da argila nos campos.

Ao avaliar os diversos métodos de amostragem, observou-se que o método baseado no GRID-1 se destacou, registrando os menores erros (RMSE mais baixos) para todos os atributos do solo. Esse resultado se justifica pelo fato de que os campos investigados neste estudo apresentaram dependências espaciais altas e moderadas para os atributos do solo, conforme indicado pelo SDI. Em tais contextos, o ajuste de semivariogramas combinado com a interpolação por krigagem, abordagem adotada em nosso estudo, tende a fornecer boas estimativas. Em contrapartida, a significativa variabilidade espacial sugere que o método CONV, que tenta representar o campo por meio de uma única amostra de solo, pode não ser eficiente. Essa observação é reforçada ao notar que, nos campos analisados neste estudo, o método CONV apresentou os maiores valores de RMSE, indicando menor precisão nas estimativas dos atributos do solo.

As ZM delimitadas a partir de dados SAR mostraram superioridade em comparação com os métodos CONV, CEL e CEL-RND, sendo ocasionalmente superadas apenas pelos métodos CEL e CEL-RND. Assim, em cenários com recursos financeiros limitados, onde a amostragem convencional é escolhida, os dados SAR podem ser utilizados para orientar a amostragem por meio das ZM. O método apresentado neste estudo oferece aos especialistas a oportunidade de prestar serviços de forma remota, eliminando a necessidade de visitas a campo.

Isso resulta em economia de custos e facilita a implementação da agricultura de precisão, mesmo para pequenos agricultores.

2.5 CONCLUSÃO

A estratégia que combina *autoencoders* com o índice VV/VH resultou em estimativas mais precisas dos atributos do solo em comparação com outros índices de Radar de Abertura Sintética (SAR). O método GRID-1, que utiliza um grid de pontos de alta densidade seguido de interpolação por krigagem, destacou-se como a técnica mais eficaz para o mapeamento de atributos do solo, enquanto o método convencional de amostragem de solo (CONV) apresentou o pior desempenho. As Zonas de Manejo (ZM) delineadas utilizando o índice VV/VH com base em *autoencoders* superaram o método CONV, o método de amostragem de solo pautado em células aleatórias (CEL-RND) e, em muitos casos, o método de amostragem em células retangulares (CEL). Esses resultados são promissores e indicam o potencial dos dados SAR na análise da variabilidade do solo e na definição de ZM.

2.6 REFERÊNCIAS

- Ali, A., Rondelli, V., Martelli, R., Falsone, G., Lupia, F., Barbanti, L., 2022. Management Zones Delineation through Clustering Techniques Based on Soils Traits, NDVI Data, and Multiple Year Crop Yields. *Agriculture* 12, 231. <https://doi.org/10.3390/agriculture12020231>
- Amazirh, A., Merlin, O., Er-Raki, S., Gao, Q., Rivalland, V., Malbeteau, Y., Khabba, S., Escorihuela, M.J., 2018. Retrieving surface soil moisture at high spatio-temporal resolution from a synergy between Sentinel-1 radar and Landsat thermal data: A study case over bare soil. *Remote Sens Environ* 211, 321–337. <https://doi.org/10.1016/j.rse.2018.04.013>
- Azizi, K., Garosi, Y., Ayoubi, S., Tajik, S., 2023. Integration of Sentinel-1/2 and topographic attributes to predict the spatial distribution of soil texture fractions in some agricultural soils of western Iran. *Soil Tillage Res* 229, 105681. <https://doi.org/10.1016/j.still.2023.105681>
- Balenzano, A., Mattia, F., Satalino, G., Lovergine, F.P., Palmisano, D., Peng, J., Marzahn, P., Wegmüller, U., Cartus, O., Dąbrowska-Zielińska, K., Musial, J.P., Davidson, M.W.J., Pauwels, V.R.N., Cosh, M.H., McNairn, H., Johnson, J.T., Walker, J.P., Yueh, S.H., Entekhabi, D., Kerr, Y.H., Jackson, T.J., 2021. Sentinel-1 soil moisture at 1 km resolution: a validation study. *Remote Sens Environ* 263, 112554. <https://doi.org/10.1016/j.rse.2021.112554>

- Bank, D., Koenigstein, N., Giryas, R., 2023. Autoencoders, in: *Machine Learning for Data Science Handbook*. Springer International Publishing, Cham, pp. 353–374. https://doi.org/10.1007/978-3-031-24628-9_16
- Bazzi, H., Baghdadi, N., El Hajj, M., Zribi, M., Minh, D.H.T., Ndikumana, E., Courault, D., Belhouchette, H., 2019. Mapping Paddy Rice Using Sentinel-1 SAR Time Series in Camargue, France. *Remote Sens (Basel)* 11, 887. <https://doi.org/10.3390/rs11070887>
- Bezdek, J.C., Ehrlich, R., Full, W., 1984. FCM: The fuzzy c-means clustering algorithm. *Comput Geosci* 10, 191–203. [https://doi.org/10.1016/0098-3004\(84\)90020-7](https://doi.org/10.1016/0098-3004(84)90020-7)
- Bioresita, F., Puissant, A., Stumpf, A., Malet, J.-P., 2019. Fusion of Sentinel-1 and Sentinel-2 image time series for permanent and temporary surface water mapping. *Int J Remote Sens* 1–24. <https://doi.org/10.1080/01431161.2019.1624869>
- Bottega, E.L., Safanelli, J.L., Zeraatpisheh, M., Amado, T.J.C., Queiroz, D.M. de, Oliveira, Z.B. de, 2022. Site-Specific Management Zones Delineation Based on Apparent Soil Electrical Conductivity in Two Contrasting Fields of Southern Brazil. *Agronomy* 12, 1390. <https://doi.org/10.3390/agronomy12061390>
- Bousbih, S., Zribi, M., Lili-Chabaane, Z., Baghdadi, N., El Hajj, M., Gao, Q., Mougenot, B., 2017. Potential of Sentinel-1 Radar Data for the Assessment of Soil and Cereal Cover Parameters. *Sensors* 17, 2617. <https://doi.org/10.3390/s17112617>
- Brock, A., Brouder, S.M., Blumhoff, G., Hofmann, B.S., 2005. Defining Yield-Based Management Zones for Corn-Soybean Rotations. *Agron J* 97, 1115–1128. <https://doi.org/10.2134/agronj2004.0220>
- Cambardella, C.A., Moorman, T.B., Novak, J.M., Parkin, T.B., Karlen, D.L., Turco, R.F., Konopka, A.E., 1994. Field-Scale Variability of Soil Properties in Central Iowa Soils. *Soil Science Society of America Journal* 58, 1501–1511. <https://doi.org/10.2136/sssaj1994.03615995005800050033x>
- Chaudhary, S.K., Srivastava, P.K., Gupta, D.K., Kumar, P., Prasad, R., Pandey, D.K., Das, A.K., Gupta, M., 2022. Machine learning algorithms for soil moisture estimation using Sentinel-1: Model development and implementation. *Advances in Space Research* 69, 1799–1812. <https://doi.org/10.1016/j.asr.2021.08.022>

Dabrowska-Zielinska, K., Musial, J., Malinska, A., Budzynska, M., Gurdak, R., Kiryla, W., Bartold, M., Grzybowski, P., 2018. Soil Moisture in the Biebrza Wetlands Retrieved from Sentinel-1 Imagery. *Remote Sens (Basel)* 10, 1979. <https://doi.org/10.3390/rs10121979>

Damian, J.M., Pias, O.H. de C., Cherubin, M.R., Fonseca, A.Z. da, Fornari, E.Z., Santi, A.L., 2020a. Applying the NDVI from satellite images in delimiting management zones for annual crops. *Sci Agric* 77. <https://doi.org/10.1590/1678-992x-2018-0055>

Damian, J.M., Pias, O.H. de C., Cherubin, M.R., Fonseca, A.Z. da, Fornari, E.Z., Santi, A.L., 2020b. Applying the NDVI from satellite images in delimiting management zones for annual crops. *Sci Agric* 77. <https://doi.org/10.1590/1678-992x-2018-0055>

El Hajj, M., Baghdadi, N., Bazzi, H., Zribi, M., 2018. Penetration Analysis of SAR Signals in the C and L Bands for Wheat, Maize, and Grasslands. *Remote Sens (Basel)* 11, 31. <https://doi.org/10.3390/rs11010031>

Farr, T.G., Rosen, P.A., Caro, E., Crippen, R., Duren, R., Hensley, S., Kobrick, M., Paller, M., Rodriguez, E., Roth, L., Seal, D., Shaffer, S., Shimada, J., Umland, J., Werner, M., Oskin, M., Burbank, D., Alsdorf, D., 2007. The Shuttle Radar Topography Mission. *Reviews of Geophysics* 45. <https://doi.org/10.1029/2005RG000183>

Fleming, K.L., Westfall, D.G., Wiens, D.W., Brodahl, M.C., 2000. Evaluating Farmer Defined Management Zone Maps for Variable Rate Fertilizer Application. *Precis Agric* 2, 201–215. <https://doi.org/10.1023/A:1011481832064>

Franzen, D.W., Peck, T.R., 1995. Field Soil Sampling Density for Variable Rate Fertilization. *Journal of Production Agriculture* 8, 568–574. <https://doi.org/10.2134/jpa1995.0568>

Frison, P.-L., Fruneau, B., Kmiha, S., Soudani, K., Dufrêne, E., Toan, T. Le, Koleck, T., Villard, L., Mougin, E., Rudant, J.-P., 2018. Potential of Sentinel-1 Data for Monitoring Temperate Mixed Forest Phenology. *Remote Sens (Basel)* 10, 2049. <https://doi.org/10.3390/rs10122049>

Gao, Q., Zribi, M., Escorihuela, M., Baghdadi, N., 2017. Synergetic Use of Sentinel-1 and Sentinel-2 Data for Soil Moisture Mapping at 100 m Resolution. *Sensors* 17, 1966. <https://doi.org/10.3390/s17091966>

Garosi, Y., Ayoubi, S., Nussbaum, M., Sheklabadi, M., Nael, M., Kimiaee, I., 2022. Use of the time series and multi-temporal features of Sentinel-1/2 satellite imagery to predict soil inorganic and organic carbon in a low-relief area with a semi-arid environment. *Int J Remote Sens* 43, 6856–6880. <https://doi.org/10.1080/01431161.2022.2147037>

Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., Moore, R., 2017. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sens Environ* 202, 18–27. <https://doi.org/10.1016/j.rse.2017.06.031>

Hoang, D.-T., Kang, H.-J., 2019. A survey on Deep Learning based bearing fault diagnosis. *Neurocomputing* 335, 327–335. <https://doi.org/10.1016/j.neucom.2018.06.078>

Isaaks, E.H., Srivastava., R.M., 1989. *Applied geostatistics*. New York: Oxford university press.

Ismail, S.M., Ozawa, K., 2007. Improvement of crop yield, soil moisture distribution and water use efficiency in sandy soils by clay application. *Appl Clay Sci* 37, 81–89. <https://doi.org/10.1016/j.clay.2006.12.005>

Jaynes, D.B., Colvin, T.S., Kaspar, T.C., 2005. Identifying potential soybean management zones from multi-year yield data. *Comput Electron Agric* 46, 309–327. <https://doi.org/10.1016/j.compag.2004.11.011>

Ju, J., Roy, D.P., 2008. The availability of cloud-free Landsat ETM+ data over the conterminous United States and globally. *Remote Sens Environ* 112, 1196–1211. <https://doi.org/10.1016/j.rse.2007.08.011>

Kaushik, S.K., Mishra, V.N., Punia, M., Diwate, P., Sivasankar, T., Soni, A.K., 2021. Crop Health Assessment Using Sentinel-1 SAR Time Series Data in a Part of Central India. *Remote Sens Earth Syst Sci* 4, 217–234. <https://doi.org/10.1007/s41976-021-00064-z>

Lasko, K., Vadrevu, K.P., Tran, V.T., Justice, C., 2018. Mapping Double and Single Crop Paddy Rice With Sentinel-1A at Varying Spatial Scales and Polarizations in Hanoi, Vietnam. *IEEE J Sel Top Appl Earth Obs Remote Sens* 11, 498–512. <https://doi.org/10.1109/JSTARS.2017.2784784>

- Lauzon, J.D., O'Halloran, I.P., Fallow, D.J., von Bertoldi, A.P., Aspinall, D., 2005. Spatial Variability of Soil Test Phosphorus, Potassium, and pH of Ontario Soils. *Agron J* 97, 524–532. <https://doi.org/10.2134/agronj2005.0524>
- Lawrence, P.G., Roper, W., Morris, T.F., Guillard, K., 2020. Guiding soil sampling strategies using classical and spatial statistics: A review. *Agron J* 112, 493–510. <https://doi.org/10.1002/agj2.20048>
- Lee, J.-S., Grunes, M.R., de Grandi, G., 1999. Polarimetric SAR speckle filtering and its implication for classification. *IEEE Transactions on Geoscience and Remote Sensing* 37, 2363–2373. <https://doi.org/10.1109/36.789635>
- Maldonado, W., Valeriano, T.T.B., de Souza Rolim, G., 2019. EVAPO: A smartphone application to estimate potential evapotranspiration using cloud gridded meteorological data from NASA-POWER system. *Comput Electron Agric* 156, 187–192. <https://doi.org/10.1016/j.compag.2018.10.032>
- Miles, K.E., Willis, I.C., Benedek, C.L., Williamson, A.G., Tedesco, M., 2017. Toward Monitoring Surface and Subsurface Lakes on the Greenland Ice Sheet Using Sentinel-1 SAR and Landsat-8 OLI Imagery. *Front Earth Sci (Lausanne)* 5. <https://doi.org/10.3389/feart.2017.00058>
- Mirzaeitalarposhti, R., Shafizadeh-Moghadam, H., Taghizadeh-Mehrjardi, R., Demyan, M.S., 2022. Digital Soil Texture Mapping and Spatial Transferability of Machine Learning Models Using Sentinel-1, Sentinel-2, and Terrain-Derived Covariates. *Remote Sens (Basel)* 14, 5909. <https://doi.org/10.3390/rs14235909>
- Moral, F.J., Terrón, J.M., Silva, J.R.M. da, 2010. Delineation of management zones using mobile measurements of soil apparent electrical conductivity and multivariate geostatistical techniques. *Soil Tillage Res* 106, 335–343. <https://doi.org/10.1016/j.still.2009.12.002>
- Mullissa, A., Vollrath, A., Odongo-Braun, C., Slagter, B., Balling, J., Gou, Y., Gorelick, N., Reiche, J., 2021. Sentinel-1 SAR Backscatter Analysis Ready Data Preparation in Google Earth Engine. *Remote Sens (Basel)* 13, 1954. <https://doi.org/10.3390/rs13101954>

Pelta, R., Beerli, O., Tarshish, R., Shilo, T., 2022. Sentinel-1 to NDVI for Agricultural Fields Using Hyperlocal Dynamic Machine Learning Approach. *Remote Sens (Basel)* 14, 2600. <https://doi.org/10.3390/rs14112600>

Peralta, N.R., Costa, J.L., 2013. Delineation of management zones with soil apparent electrical conductivity to improve nutrient management. *Comput Electron Agric* 99, 218–226. <https://doi.org/10.1016/j.compag.2013.09.014>

Quegan, S., Jiong Jiong Yu, 2001. Filtering of multichannel SAR images. *IEEE Transactions on Geoscience and Remote Sensing* 39, 2373–2379. <https://doi.org/10.1109/36.964973>

Queiroz, D.M. de, Coelho, A.L. de F., Valente, D.S.M., Schueller, J.K., 2020. Sensors Applied to Digital Agriculture: A Review. *REVISTA CIÊNCIA AGRONÔMICA* 51. <https://doi.org/10.5935/1806-6690.20200086>

Rossini, P.R., Ciampitti, I.A., Hefley, T., Patrignani, A., 2021. A soil moisture-based framework for guiding the number and location of soil moisture sensors in agricultural fields. *Vadose Zone Journal* 20. <https://doi.org/10.1002/vzj2.20159>

Schmidt, K., Schwerdt, M., Miranda, N., Reimann, J., 2020. Radiometric Comparison within the Sentinel-1 SAR Constellation over a Wide Backscatter Range. *Remote Sens (Basel)* 12, 854. <https://doi.org/10.3390/rs12050854>

Solos Embrapa, 2013. Sistema brasileiro de classificação de solos. Centro Nacional de Pesquisa de Solos: Rio de Janeiro 3.

Soudani, K., Delpierre, N., Berveiller, D., Hmimina, G., Vincent, G., Morfin, A., Dufrêne, É., 2021. Potential of C-band Synthetic Aperture Radar Sentinel-1 time-series for the monitoring of phenological cycles in a deciduous forest. *International Journal of Applied Earth Observation and Geoinformation* 104, 102505. <https://doi.org/10.1016/j.jag.2021.102505>

Stasolla, M., Neyt, X., 2018. An Operational Tool for the Automatic Detection and Removal of Border Noise in Sentinel-1 GRD Products. *Sensors* 18, 3454. <https://doi.org/10.3390/s18103454>

Torres, R., Snoeij, P., Geudtner, D., Bibby, D., Davidson, M., Attema, E., Potin, P., Rommen, B., Floury, N., Brown, M., Traver, I.N., Deghaye, P., Duesmann, B., Rosich, B., Miranda, N.,

- Bruno, C., L'Abbate, M., Croci, R., Pietropaolo, A., Huchler, M., Rostan, F., 2012. GMES Sentinel-1 mission. *Remote Sens Environ* 120, 9–24. <https://doi.org/10.1016/j.rse.2011.05.028>
- Valente, D.S.M., Queiroz, D.M. de, Pinto, F. de A. de C., Santos, N.T., Santos, F.L., 2012. Definition of management zones in coffee production fields based on apparent soil electrical conductivity. *Sci Agric* 69, 173–179. <https://doi.org/10.1590/S0103-90162012000300001>
- Veloso, A., Mermoz, S., Bouvet, A., Le Toan, T., Planells, M., Dejoux, J.-F., Ceschia, E., 2017. Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications. *Remote Sens Environ* 199, 415–426. <https://doi.org/10.1016/j.rse.2017.07.015>
- Vickers, H., Malnes, E., Høgda, K.-A., 2019. Long-Term Water Surface Area Monitoring and Derived Water Level Using Synthetic Aperture Radar (SAR) at Altevatn, a Medium-Sized Arctic Lake. *Remote Sens (Basel)* 11, 2780. <https://doi.org/10.3390/rs11232780>
- Voronoi, G., 1908. Nouvelles applications des paramètres continus à la théorie des formes quadratiques. Deuxième mémoire. Recherches sur les paralléloèdres primitifs. *Journal für die reine und angewandte Mathematik (Crelles Journal)* 1908, 198–287. <https://doi.org/10.1515/crll.1908.134.198>
- Warrick, A.W., Nielsen, D.R., 1980. Spatial variability of soil physical properties in the field. *Applications of Soil Physics*, New York.
- Webster, R., Oliver, M.A., 1992. Sample adequately to estimate variograms of soil properties. *Journal of Soil Science* 43, 177–192. <https://doi.org/10.1111/j.1365-2389.1992.tb00128.x>
- Wei, J., Huang, W., Li, Z., Sun, L., Zhu, X., Yuan, Q., Liu, L., Cribb, M., 2020. Cloud detection for Landsat imagery by combining the random forest and superpixels extracted via energy-driven sampling segmentation approaches. *Remote Sens Environ* 248, 112005. <https://doi.org/10.1016/j.rse.2020.112005>
- Xing, L., Tang, X., Wang, H., Fan, W., Wang, G., 2018. Monitoring monthly surface water dynamics of Dongting Lake using Sentinel-1 data at 10 m. *PeerJ* 6, e4992. <https://doi.org/10.7717/peerj.4992>

Yang, R.-M., Guo, W.-W., 2019. Modelling of soil organic carbon and bulk density in invaded coastal wetlands using Sentinel-1 imagery. *International Journal of Applied Earth Observation and Geoinformation* 82, 101906. <https://doi.org/10.1016/j.jag.2019.101906>

3 ARTIGO II - POTENCIAL DA SÉRIE TEMPORAL DO ÍNDICE VV/VH DO SENTINEL-1 NA DELIMITAÇÃO DE ZONAS DE MANEJO

RESUMO

A delimitação de Zonas de Manejo (ZMs) geralmente utiliza mapas de produtividade e índices multiespectrais como NDVI, mas a falta de calibração dos monitores de colheita e a cobertura de nuvens frequentemente comprometem a qualidade dos dados históricos. O objetivo deste estudo foi propor um método alternativo para delimitação de ZMs utilizando o índice VV/VH do Sentinel-1 e comparar sua acurácia com métodos tradicionais na estimativa de atributos do solo e na identificação de zonas de alta e baixa produtividade. Foram avaliadas três abordagens: ZMs delimitadas com base em mapas de produtividade, no índice NDVI e no índice VV/VH. O estudo foi conduzido em um campo agrícola comercial, abrangendo dados de atributos do solo e mapas de produtividade de cultivos de algodão e milho entre 2019 e 2023. As imagens dos satélites Sentinel-2 e Sentinel-1, utilizadas no cálculo do NDVI e VV/VH, respectivamente, foram obtidas por meio da plataforma Google Earth Engine. A partir dos mapas de produtividade e das imagens NDVI, foram gerados mapas de tendência espacial e temporal, classificados em três categorias: (i) Alto e Estável – zonas de elevada produtividade e NDVI com alta estabilidade; (ii) Baixo e Estável – zonas de baixa produtividade e NDVI com alta estabilidade; e (iii) Instável – zonas com alta variação interanual de produtividade e NDVI. Para delimitar as ZMs por meio do índice VV/VH, foi utilizado um *autoencoder* de *deep learning* para reduzir a dimensionalidade da série temporal VV/VH. Em seguida, aplicou-se o algoritmo *fuzzy k-means* para a definição do número de zonas, considerando $k = 3$. O método de validação cruzada deixe-um-de-fora foi utilizado para avaliar o desempenho de cada método. Os valores de erro, quantificados pelo RMSE, obtidos na validação cruzada na estimativa dos atributos do solo foram semelhantes na maioria dos casos. No entanto, o método VV/VH apresentou um RMSE significativamente menor para argila (4,71) em comparação aos métodos mapas de produtividade (6,79) e NDVI (6,11). Ambos os métodos NDVI e VV/VH mostraram boa capacidade para identificar zonas de alta e baixa produtividade, com erros similares (RMSE de 4,27 e 4,32, respectivamente). Os resultados indicam que o índice VV/VH é uma alternativa promissora para a delimitação de ZMs, apresentando desempenho comparável ao NDVI e mapas de produtividade na estimativa de atributos do solo e eficácia similar ao NDVI na identificação de zonas de alta e baixa produtividade.

Palavras-chave: Agricultura de precisão, Sensoriamento Remoto, Amostragem de solo

ABSTRACT

The delineation of Management Zones (MZs) generally utilizes productivity maps and multispectral indices such as NDVI, but the lack of calibration of yield monitors and cloud cover often compromise the quality of historical data. This study aimed to propose an alternative method for MZs delineation using the VV/VH index from Sentinel-1 and to compare its accuracy with traditional methods in estimating soil attributes and identifying high- and low-productivity zones. Three approaches were evaluated: MZs delineated based on yield maps, the NDVI index, and the VV/VH index. The study was conducted in a commercial agricultural field, incorporating soil attribute data and yield maps from cotton and maize crops between 2019 and 2023. Satellite images from Sentinel-2 and Sentinel-1, used to calculate NDVI and VV/VH, respectively, were obtained through the Google Earth Engine platform. From yield maps and NDVI images, spatial and temporal trend maps were generated and classified into three categories: (i) High and Stable – zones with high yield and NDVI with strong stability; (ii) Low and Stable – zones with low yield and NDVI, also exhibiting high stability; and (iii) Unstable – zones with high interannual variability in yield and NDVI. To delineate MZs using the VV/VH index, a deep learning autoencoder was applied to reduce the dimensionality of the VV/VH time series. Subsequently, the fuzzy k-means algorithm was used to define the number of zones, considering $k = 3$. The leave-one-out cross-validation method was used to evaluate the performance of each approach. The error values, quantified by RMSE, obtained in the cross-validation for soil attribute estimation were similar in most cases. However, the VV/VH method achieved a significantly lower RMSE (4.71) compared to the yield map (6.79) and NDVI-based methods (6.11). Both the NDVI and VV/VH methods demonstrated strong capability in identifying high- and low-productivity zones, with similar errors (RMSE of 4.27 and 4.32, respectively). These results indicate that the VV/VH index is a promising alternative for MZ delineation, showing performance comparable to NDVI and yield maps in estimating soil attributes and similar effectiveness to NDVI in identifying productivity zones.

Keywords: Precision Agriculture, Remote Sensing, Soil Sampling, Synthetic Aperture Radar, Deep Learning

3.1 INTRODUÇÃO

A Agricultura de Precisão (AP) está na linha de frente da gestão agrícola moderna, reunindo diversas iniciativas em pesquisa, desenvolvimento e inovação (Barbosa Júnior et al., 2024). Seu principal objetivo é otimizar as práticas agrícolas, promovendo maior eficiência no uso de recursos e reduzindo os impactos ambientais (Kendall et al., 2022; Soussi et al., 2024). Entre as principais práticas agrícolas, destaca-se o manejo da fertilidade do solo, uma vez que a variabilidade nos atributos do solo pode impactar significativamente o rendimento das culturas. Nesse contexto, a coleta precisa de dados sobre os atributos do solo é fundamental para a implementação eficaz da AP, permitindo a aplicação localizada e racional de fertilizantes com base nas necessidades específicas de cada área (Queiroz et al., 2020).

Apesar da crescente adoção de técnicas de AP, a otimização dos métodos de amostragem de solo para caracterizar sua variabilidade espacial continua sendo um desafio significativo (Valente et al., 2024). Ferramentas como o Smart-Map têm se destacado na construção de mapas digitais de atributos do solo, utilizando abordagens matemáticas, estatísticas e de aprendizado de máquina (Pereira et al., 2022). No entanto, as propriedades físico-químicas do solo apresentam um elevado grau de variação espacial, influenciado por diferentes usos da terra e condições climáticas em escalas espaço-temporais distintas (Moharana et al., 2020; Shashikumar et al., 2023). A construção de mapas digitais de atributos do solo com elevada acurácia depende fortemente da estratégia de amostragem, da densidade de amostras coletadas e do grau de variabilidade intrínseca do solo. Webster e Oliver (1992) demonstraram que variogramas utilizados para inferir atributos do solo em pontos não amostrados tornam-se pouco confiáveis quando modelados com base em dados obtidos utilizando grades com menos de 100 pontos de amostragem. Assim, embora a amostragem em grade possa oferecer uma base sólida para a construção de mapas digitais de atributos do solo, com densidades amostrais da ordem de uma amostra por hectare, os custos associados e a elevada demanda por mão de obra, especialmente em áreas extensas com alta variabilidade, podem inviabilizar sua aplicação prática. Esses desafios podem comprometer a implementação de técnicas de AP e afetar negativamente a sustentabilidade socioambiental da produção agrícola.

Alguns estudos indicam que alternativas à amostragem de solo com base em grades de alta densidade podem ser implementadas para reduzir a quantidade de amostras necessárias, mantendo ou até aprimorando a precisão na caracterização da variabilidade dos atributos do solo. Uma dessas alternativas é a delimitação de Zonas de Manejo (ZMs), que envolve a

subdivisão da área em regiões homogêneas, identificadas a partir da variabilidade detectada por sensores de solo, como a condutividade elétrica aparente do solo (Bottega et al., 2022; Peralta and Costa 2013; Valente et al., 2012, 2024), ou de características relacionadas ao desenvolvimento das plantas e ao mapa de produtividade das culturas (Blackmore 2000; Blackmore et al., 2003; Brock et al., 2005; Damian et al., 2020; Speranza et al., 2023). Nessa técnica, as amostras simples de solo são coletadas em cada ZM que misturadas formam uma amostra representativa da zona, possibilitando a geração de prescrições de insumos específicas para cada zona, fundamentadas no potencial produtivo e nos valores médios dos atributos de solo em cada uma delas. Esse tipo de estratégia de amostragem do solo por zona reduz o número de amostras necessárias para caracterizar a variabilidade espacial do solo. A utilização de mapas de produtividade ao longo do tempo para delimitar ZMs com alto e baixo potencial de rendimento se destaca como alternativa eficaz, considerando que nem todos os atributos do solo seguem o mesmo padrão de variabilidade. Dessa forma, o uso dos mapas alinha as ZMs ao padrão de variabilidade dos atributos que limitam a produtividade das culturas, garantindo maior acurácia nas estimativas desses atributos.

Embora os mapas de produtividade estejam disponíveis desde o início da década de 1990, sua adoção em larga escala, tem ocorrido de forma lenta. Apesar do aumento no uso nos últimos anos, essa tecnologia foi adotada em apenas 5% a 25% da área total cultivada nos Estados Unidos para culturas como trigo de inverno, algodão, sorgo e arroz (McFadden et al., 2023). Para milho e soja, a adoção é maior, atingindo cerca de 45%. Um dos fatores que contribuem para a baixa adoção é que atividades periféricas, não diretamente relacionadas à colheita ou produção imediata, frequentemente recebem menor prioridade entre os produtores. Por exemplo, estudos destacam que a calibração dos monitores de produtividade para o algodão deve ser feita para cada tipo de cultivar, sob o risco de perda de acurácia nas medições (Pelletier et al., 2019; Vories et al., 2019). Outro desafio está na interpretação dos padrões espaciais e temporais das produtividades, que podem ser confundidos por fatores como variabilidade climática, mudanças na qualidade do solo, pressão de pragas e outras condições prevalentes durante a safra (Basso et al., 2012). Nesses casos, é essencial dispor de um histórico longo e consistente de dados de produtividade para garantir maior confiabilidade nas informações geradas pelos mapas. No entanto, obter mapas de produtividade de qualidade ao longo do tempo pode ser um desafio, o que indica que outras abordagens podem ser mais aplicáveis e economicamente viáveis em determinados contextos.

O sensoriamento remoto por meio de sensores ópticos multiespectrais disponíveis em plataformas orbitais como o Landsat-8 e o Sentinel-2, juntamente com sensores de micro-ondas

ativos, como o radar de abertura sintética (SAR) do Sentinel-1, tem se consolidado como uma ferramenta essencial em diversas aplicações agrícolas. Estudos destacam consistentemente a relação entre a produtividade das culturas e índices espectrais, como o *Normalized Difference Vegetation Index* (NDVI), derivados de sensores ópticos multiespectrais, bem como sua aplicação na delimitação de ZMs e na estimativa de atributos do solo (Ali et al., 2022; Amaral et al., 2024; Esteves et al., 2022; Macedo et al., 2023; Zhou et al., 2022). A integração das imagens das plataformas Landsat-8 e Sentinel-2 oferece um tempo médio global de revisita de aproximadamente 2,9 dias (Li e Roy, 2017), ampliando significativamente a capacidade de monitorar o desenvolvimento das culturas. No entanto, índices multiespectrais como o NDVI refletem predominantemente a condição da biomassa e da cobertura vegetal, uma vez que a luz vermelha infravermelho utilizada em seu cálculo possui uma capacidade limitada de penetração no dossel das culturas. Essa característica restringe sua sensibilidade às camadas da vegetação mais próximas ao solo (Gitelson et al., 2014). Além disso, os índices derivados de dados ópticos multiespectrais apresentam uma limitação significativa por não possuírem capacidade de penetração em nuvens, o que impede a aquisição de imagens úteis em dias nublados. Esse desafio é especialmente relevante em regiões tropicais, onde a cobertura média anual de nuvens chega a aproximadamente 66%, tornando a construção de séries históricas representativas, particularmente para culturas anuais, um processo desafiador (Ju e Roy, 2008; Wei et al., 2020).

Por outro lado, o Sentinel-1 utiliza um sistema de observação ativo que emite radiação eletromagnética de comprimentos de onda longos, permitindo sua penetração em praticamente todas as condições climáticas, incluindo nuvens, neblina, areia e poeira, com exceção de chuvas intensas (Li et al., 2022). Essa característica possibilita a aquisição de imagens tanto durante o dia quanto à noite, garantindo monitoramento contínuo e confiável. Além disso, as radiações eletromagnéticas de comprimentos de onda longos têm a capacidade de atravessar não apenas as camadas superficiais da vegetação, mas também alcançar camadas mais profundas e penetrar o solo. Por exemplo, em solos agrícolas descobertos, o sinal de radar retroespalhado é altamente influenciado por características geométricas, como rugosidade, teor de água e composição química do solo (Aubert et al., 2011). Quando o solo está coberto por culturas como por exemplo, soja, milho e trigo, o sinal de radar sofre mudanças temporais semelhantes ao NDVI, indicando que o sinal SAR também contém informações sobre o verde da vegetação e o conteúdo de água (Veloso et al., 2017). Essas propriedades tornam as imagens SAR mais ricas em informações espaço-temporais do que as imagens multiespectrais, consolidando-as como uma ferramenta poderosa para a análise detalhada de solos e vegetação.

Os dados SAR têm sido amplamente empregados, individualmente ou em combinação

com dados multiespectrais, em diversas aplicações, incluindo estimativa de umidade do solo (Balenzano et al. 2021; Chaudhary et al. 2022; Rossini et al. 2021), caracterização de atributos físicos do solo, como densidade e textura (Azizi et al., 2023; Garosi et al., 2022; Mirzaeitalarposhti et al., 2022; Yang and Guo 2019) e estimativa de índices multiespectrais, como o NDVI (Frison et al., 2018b; Kaushik et al., 2021; Veloso et al., 2017). Recentemente, Gonçalves et al. (2025) utilizaram dados SAR na ZMs e concluíram que a estratégia que combina um algoritmo de *deep learning autoencoders* com o índice SAR VV/VH (polarização VV - vertical-vertical e VH - vertical-horizontal) resultou em estimativas mais precisas dos atributos do solo, superando tanto o método convencional de amostragem (uma amostra composta) quanto o método de amostragem de solo com base em células retangulares (uma amostra composta por célula). Contudo, o desempenho deste métodos, com base em dados de radar, não foi comparado com métodos tradicionais de delimitação de ZMs, como aqueles que utilizam mapas de produtividade e/ou imagens NDVI.

Portanto, o objetivo principal deste estudo foi comparar a acurácia das ZMs definidas com base no índice VV/VH derivado do Sentinel-1 na estimativa de atributos do solo em relação a métodos tradicionais que utilizam mapas de produtividade e índice NDVI. Como objetivo secundário, avaliou-se a acurácia das ZMs delimitadas pelos índices NDVI e VV/VH na previsão da produtividade média padronizada utilizando mapas de produtividade coletados ao longo dos anos.

3.2 MATERIAL E MÉTODOS

3.2.1 Local de estudo e conjunto de dados

O presente estudo foi conduzido numa área agrícola comercial de 232 hectares com cultivos de algodão, milho e soja, localizada no município de Tangará da Serra, estado de Mato Grosso, Brasil (Fig. 1). O solo foi classificado como Latossolo Vermelho distroférico típico (Embrapa 2013) e cultivado em sistema de plantio direto. Para caracterização dos atributos do solo, adotou-se o método de amostragem em malha por ponto, com um espaçamento de aproximadamente 150 metros, resultado em 77 amostras. A partir da malha de pontos, foram determinados em laboratório os valores de 10 atributos do solo. As estatísticas descritivas desses atributos estão resumidas na Tabela 1.

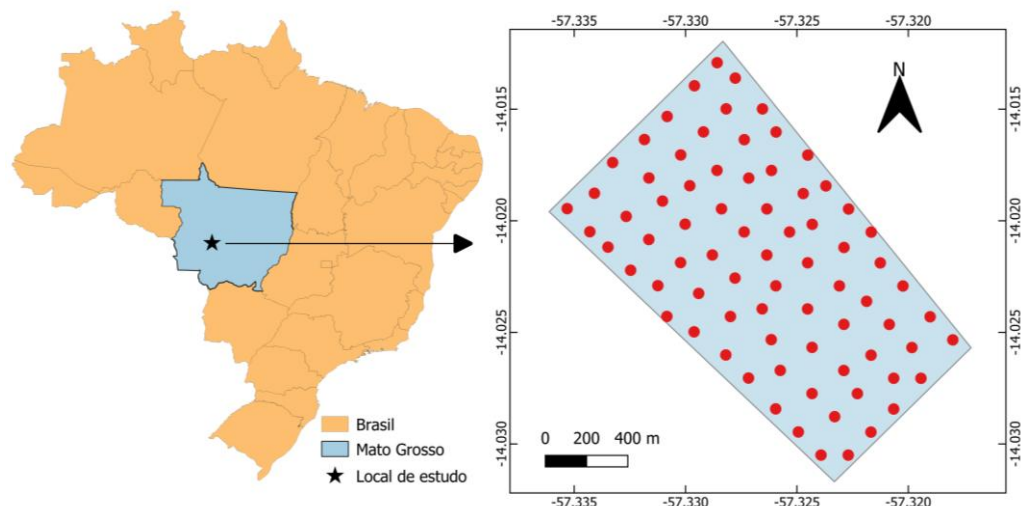


Figura 1. Área de estudo e a sua respectiva grade de amostragem.

Tabela 1. Estatística descritiva dos atributos de solo obtidos para a área de estudo com base nas amostras de solo obtidas pelo método de amostragem em malha por pontos

Atributo	Unidade	Média	Min	Max	SD	CV (%)
pH	-	5,58	4,90	6,00	0,20	4,00
Ca ²⁺	cmolc/dm ³	2,88	2,00	4,10	0,43	15,00
Mg ²⁺	cmolc/dm ³	1,52	0,90	2,20	0,28	19,00
K ⁺	cmolc/dm ³	0,23	0,14	0,37	0,05	22,00
P_Mehlich	mg/dm ³	6,93	4,00	16,30	2,44	35,00
P_Resina	mg/dm ³	21,88	12,00	61,00	7,96	36,00
MO	%	1,83	1,40	2,40	0,22	12,00
CTC	molc/dm ³	7,58	6,30	9,30	0,61	8,00
V	%	61,04	41,00	74,00	6,47	11,00
Argila	%	48,31	28,10	61,10	8,50	18,00

pH: Acidez ativa na água; Ca²⁺: Cálcio; Mg²⁺: Magnésio; K⁺: Potássio; P: Fósforo; MO: Matéria Orgânica; CTC: Capacidade de Troca Catiônica; V: Saturação por bases; SD: Desvio padrão; CV: coeficiente de variação (%).

Os dados históricos de produtividade da área de estudo foram coletados por colhedoras autopropelidas da marca John Deere. Após a aquisição, os dados passaram por um processo de pré-processamento para a remoção de outliers e valores inconsistentes. Esse processo foi conduzido em duas etapas. Na Etapa 1, foram removidos os valores fora de um intervalo mínimo e máximo aceitável, estabelecido conforme as características específicas de cada cultura e ano. Na Etapa 2, houve a exclusão manual de pontos nos mapas que indicavam manobras e operações onde a plataforma da colhedora poderia não estar totalmente carregada. A Figura 2 apresenta os mapas de produtividade gerados pela colhedora após o processo de limpeza, acompanhados do percentual de pontos removidos e das estatísticas descritivas dos dados (Tabela 2).

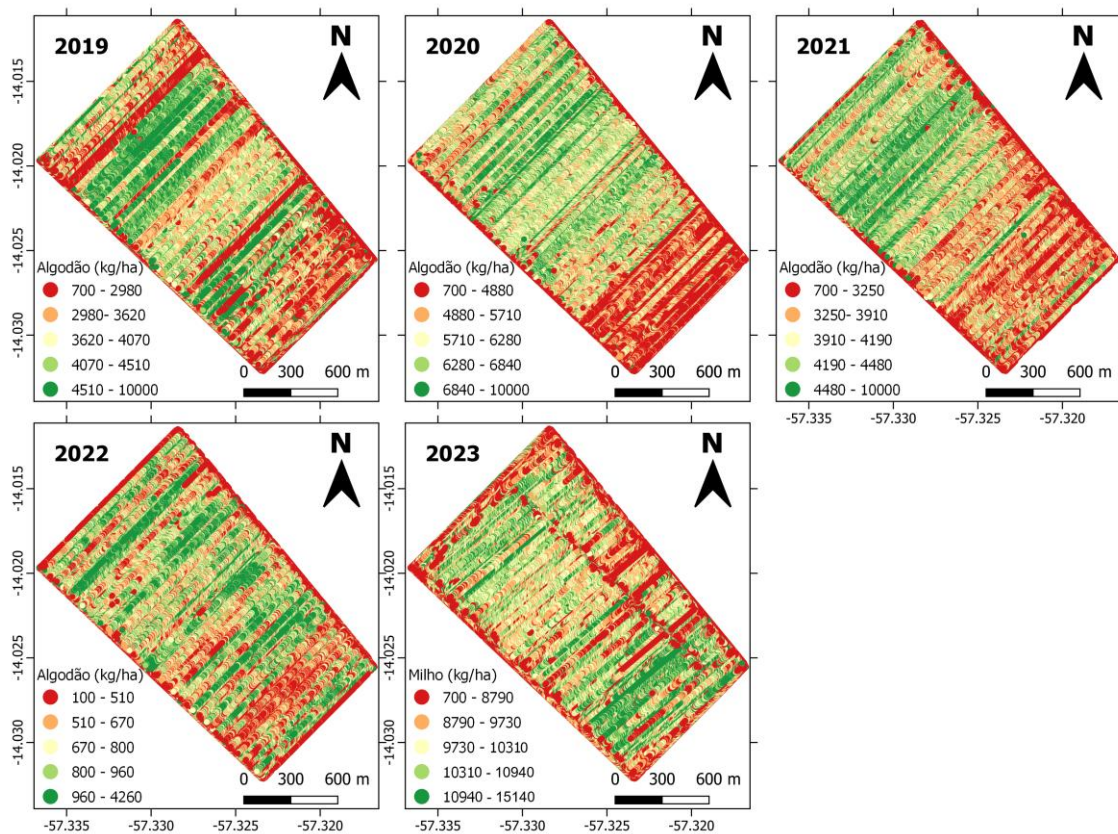


Figura 2. Dados de produtividade após pré-processamento ao longo dos anos de estudo (2019-2023).

Tabela 2. Estatísticas descritivas dos conjuntos de dados de produtividade selecionados após limpeza.

Ano	Cultura	Data de semeadura	Data de colheita	% de pontos removidos	Mínimo (kg ha ⁻¹)	Máximo (kg ha ⁻¹)	Média (kg ha ⁻¹)	CV (%)
2019	Algodão	16/01/2019	29/07/2019	3	700	1000	3720	27,32
2020	Algodão	22/01/2020	19/07/2020	3	700	10000	5790	22,72
2021	Algodão	11/02/2021	28/08/2021	1	700	10000	3950	17,96
2022	Algodão	06/02/2022	27/06/2022	1	100	4260	740	37,13
2023	Milho	30/03/2023	01/08/2023	8	700	1514	9680	19,33

CV: coeficiente de variação (%).

Após o pré-processamento dos dados de produtividade, foi realizada a interpolação utilizando o método de krigagem ordinária, a partir da modelagem e ajuste de semivariogramas. Esse processo foi conduzido com o auxílio do plugin Smart-Map (Pereira et al., 2022) no QGIS versão 3.28 (QGIS Development Team, 2018). Durante o ajuste dos modelos teóricos de semivariância aos semivariogramas experimentais, foram estimados os parâmetros: efeito pepita (C_0), patamar ($C_0 + C$), patamar parcial (C) e alcance (A). A seleção do modelo mais apropriado considerou os modelos esférico, exponencial, gaussiano e linear, utilizando critérios como maximização do coeficiente de determinação (R^2), minimização da soma dos resíduos quadráticos e coeficiente de correlação obtido na validação cruzada.

3.2.2 Imagens de sensoriamento remoto

Os dados de radar de abertura sintética (SAR) utilizados neste trabalho são provenientes da missão Sentinel-1, parte do programa Copernicus da União Europeia. Essa missão conta com uma constelação de dois satélites: o Sentinel-1A, lançado em 3 de abril de 2014, e o Sentinel-1B, lançado em 25 de abril de 2016. No entanto, o Sentinel-1B deixou de fornecer dados em 23 de dezembro de 2021. Os sensores de ambos os satélites operam na banda C, com uma frequência central de 5,405 GHz e em polarização dupla (VV - vertical-vertical e VH - vertical-horizontal). A frequência temporal das imagens varia de 6 a 12 dias em diferentes partes do mundo, podendo ser mais frequente em regiões onde ocorre sobreposição de passagens. As imagens têm espaçamento de pixels de 10 metros e uma resolução espacial de 20 x 22 metros (Torres et al. 2012).

Para a aquisição das imagens SAR, utilizou-se a coleção Sentinel-1 disponibilizada no Google Earth Engine (GEE) (https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S1_GRD). As imagens estão no formato de Dados em Alcance Terrestre Detectados (GRD), processadas com a caixa de ferramentas do Sentinel-1 para gerar produtos calibrados e ortorretificados. Esses produtos são oferecidos com o coeficiente de retroespalhamento em decibéis (dB) em escala logarítmica. O processo de pré-processamento incluiu a remoção de ruído térmico, calibração radiométrica e correção de terreno, utilizando dados da Missão Topográfica Radar Shuttle (SRTM) com resolução de 30 metros (<https://developers.google.com/earth-engine/sentinel1>). Todos os códigos do GEE para o pré-processamento dos dados do Sentinel-1 estão disponíveis em https://github.com/adugnag/gee_s1_ard (Mullissa et al. 2021).

As imagens SAR utilizadas neste estudo cobriram a área de interesse de 08/01/2018 a 29/07/2023. Cada imagem foi convertida em tabela e armazenada para a criação de perfis temporais de retroespalhamento VV e VH. Foi estabelecida uma grade de quadriláteros de 40 m x 40 m e, para cada imagem, calculou-se a média dos valores dos pixels dentro de cada quadrilátero. Posteriormente, foi gerado o índice SAR com base na razão VV/VH, que tem demonstrado desempenho superior em comparação ao uso isolado de cada banda VV e VH em diversas aplicações (Bazzi et al., 2019; Lasko et al., 2018; Veloso et al., 2017). Por fim, a razão VV/VH foi padronizada para cada quadrilátero por meio da normalização de pontuação z, ajustando a série temporal de forma que cada quadrilátero apresentasse uma média de 0 (zero) com desvio padrão de 1 (um).

Os dados multiespectrais utilizados neste estudo pertencem à missão Sentinel-2, composta por dois satélites: Sentinel-2A, lançado em 23 de junho de 2015, e Sentinel-2B, lançado em 7 de março de 2017. O Sentinel-2 é equipado com o Sensor Multiespectral Instrument (MSI), que abrange 13 bandas espectrais com diferentes resoluções espaciais e uma resolução temporal de 10 dias para um único satélite, reduzida para 5 dias quando ambos estão operacionais. No contexto da agricultura, destacam-se as bandas espectrais mais relevantes, como o azul (B2 – 490 nm), o verde (B3 – 560 nm), o vermelho (B4 – 665 nm) e o infravermelho próximo (NIR, B8 – 842 nm), todas com resolução espacial de 10 metros e as bandas da borda do vermelho (B5 – 705 nm, B6 – 740 nm, B7 – 783 nm) e o NIR estreito (B8A – 865 nm), com resolução de 20 metros.

As imagens de reflectância de superfície do Sentinel-2 foram obtidas por meio da coleção COPERNICUS/S2_SR_HARMONIZED de Nível 2A, disponibilizada pela plataforma GEE(https://developers.google.com/earthengine/datasets/catalog/COPERNICUS_S2_SR_HARMONIZED). As imagens multiespectrais de Nível 2A do Sentinel-2 fornecidas pelo GEE passaram por processos de ortorretificação e correção atmosférica, com o objetivo de reduzir os efeitos da dispersão de aerossóis atmosféricos e da dispersão de Rayleigh. As coletas das imagens foram feitas em períodos estratégicos que coincidem com o início do estágio fenológico B1 (emissão do primeiro botão floral) para o algodão e o início do estágio fenológico R1 (embonecamento/polinização) para o milho, fases em que o índice NDVI, adotado neste estudo, apresenta maior correlação com a produtividade final (Arnall et al. 2016; Maresma et al. 2020). O NDVI foi calculado com base na diferença normalizada das bandas do infravermelho próximo (B8) e do vermelho (B4). Considerando que a cobertura de nuvens representa um desafio constante na aquisição de imagens ópticas multiespectrais, buscou-se um equilíbrio na seleção das imagens, de modo a evitar vieses relacionados à maior disponibilidade de imagens em determinados anos, garantindo a consistência temporal da série de imagens analisada.

3.2.3 Delimitação de Zonas de Manejo

Para delimitar as ZMs usando os mapas de produtividade interpolados e as imagens NDVI, foi utilizada a metodologia proposta por Blackmore (2000). Este método, inicialmente elaborado para classificar dados de produtividade, considera as variações espaciais e temporais deste atributo para gerar um único mapa, que pode ser usado para fins de gerenciamento de insumos e manejos. Para determinar a tendência espacial das diferentes culturas presente na

área, determinou-se para cada mapa a produtividade percentual relativa à produtividade média (Equação 1):

$$s_i = \frac{y_i}{\bar{y}} \times 100 \quad (1)$$

em que s_i é a produtividade padronizada (%) no ponto i , y_i é a produtividade (t/ha) no ponto i e \bar{y} é a média da produtividade do mapa.

A média pontual ao longo dos anos para geração de um mapa resultante pode ser calculado pela Equação 2:

$$\bar{s}_i = \frac{\sum_{t=1}^n s_{it}}{n} \quad (2)$$

em que \bar{s}_i (%) é a média de s_i da produtividade padronizada (%), no ponto i , ao longo de n anos. Este mapa resultante indica a tendência de cada ponto da área em produzir acima ou abaixo da média da área.

Para determinar a tendência temporal, calculou-se o coeficiente de variação da produtividade relativa em cada ponto pela Equação 3:

$$CV_{si} = \frac{\left(\frac{n \sum_{t=1}^n s_{it}^2 - (\sum_{t=1}^n s_{it})^2}{n(n-1)} \right)^{0.5}}{\bar{s}_i} \times 100 \quad (3)$$

em que CV_{si} é o coeficiente de variação dados padronizados no ponto i ao longo de n anos. O mapa resultante indica o quanto a produtividade variou em um único ponto ao longo do tempo.

As mesmas equações foram aplicadas ao índice NDVI para estimar suas tendências de variação espacial e temporal. No entanto, o método proposto por Blackmore (2000) pressupõe que os dados apresentam uma distribuição simétrica. Em situações em que essa suposição não é atendida, a mediana é frequentemente considerada um estimador mais robusto do que a média, devido à sua menor sensibilidade a valores extremos. Nesses casos, em vez de adotar o valor médio dos dados como referência para o cálculo do mapa de produtividade e do NDVI padronizado (%), é recomendada a utilização da mediana.

Para determinar o grau de assimetria da distribuição dos dados, foi calculado o coeficiente de assimetria (Ca), utilizando a seguinte Equação 4:

$$Ca = \frac{n}{(n-1)(n-2)} \sum_{i=1}^n \frac{(x_i - \bar{x})^3}{s} \quad (4)$$

em que Ca é o coeficiente de assimetria, n o número de pixels, x_i é cada valor de pixel, \bar{x} é a média dos pixels e s é o desvio padrão da amostra. Distribuições com coeficiente de assimetria variando entre -2 e 2 foram consideradas aproximadamente simétricas, enquanto valores fora desse intervalo indicaram distribuições assimétricas, conforme os critérios estabelecidos por Hair (2006). Portanto, para mapas de produtividade e imagens NDVI com coeficiente de assimetria fora do intervalo estabelecido, utilizou-se a mediana como referência no cálculo do mapa de produtividade e do NDVI padronizado (%).

Com base nos mapas de tendência espacial e temporal dos dados de produtividade e NDVI, foi gerado um único mapa com três possibilidades de classes: área de elevada produtividade e elevada estabilidade (Alto e Estável) — acima da média geral (considerando todos os anos) para o campo e baixa variação interanual (limiar arbitrário); área de baixa produtividade e elevada estabilidade (Baixo e Estável) — abaixo da média geral (considerando todos os anos) para o campo e baixa variação interanual (limiar arbitrário); e área instável — alta variação interanual (limiar arbitrário). Neste trabalho, optou-se por adotar um limiar de coeficiente de variação de 20%.

Para a delimitação das ZMs utilizando a série temporal do índice VV/VH, foi implementado o método proposto por Gonçalves et al. (2025), que combina a redução da dimensionalidade da série com um processo de agrupamento. Esse método utiliza algoritmo de aprendizado de máquina profundo (*deep learning*) conhecido como *autoencoders*, redes neurais aplicadas em contextos de aprendizado não supervisionado, com o objetivo de comprimir os dados enquanto preservam ao máximo sua variabilidade intrínseca. Após o treinamento do modelo, os dados são compactados por meio da representação latente gerada pelo *autoencoder* e, em seguida, submetidos a um processo de agrupamento utilizando o algoritmo *k-means*, resultando na delimitação das ZMs.

Para otimização do modelo de *autoencoder*, foi implementado um processo de validação cruzada k- grupos, com $k=5$, visando a definição dos hiperparâmetros mais adequados. A seleção da arquitetura final baseou-se no menor erro quadrático médio obtido durante o processo de validação. A arquitetura e os parâmetros de treinamento selecionados estão detalhados nas Tabelas 3 e 4. Após o treinamento, as séries temporais de VV/VH foram compactadas por meio do *autoencoder* e, em seguida, o algoritmo *k-means* foi aplicado,

considerando três grupos de agrupamento. Esse número de grupos foi determinado com base na quantidade de classes previamente estabelecidas para as ZMs, considerando os dados de produtividade e o índice NDVI. Após o processo de agrupamento, um algoritmo adicional desenvolvido em Python foi aplicado para o refinamento dos mapas gerados, visando maior consistência espacial. Nesse estágio, agrupamentos com área inferior a 5 hectares foram automaticamente incorporados aos clusters contíguos de maior extensão, eliminando fragmentações indesejadas e garantindo a homogeneidade das ZMs delimitadas.

Tabela 3. Arquitetura de *autoencoder* proposta para extração de características.

Camadas	Tipo	Neurônios	Função de ativação
Entrada (SAR)	-	Nº de imagens SAR	-
Camada codificador	Totalmente Conectada	128	Relu
Camada codificador	Totalmente Conectada	64	Relu
Camada de redução	Totalmente Conectada	6	Relu
Camada decodificador	Totalmente Conectada	64	Relu
Camada decodificador	Totalmente Conectada	128	Relu
Camada de saída	Totalmente Conectada	Nº de imagens SAR	Linear

Tabela 4. Parâmetros utilizados para treinar a arquitetura do *autoencoder*.

Parâmetros	Valor
Número de épocas	150
Função de otimização	Adam
Taxa de aprendizado	0,0005
Tamanho de Lote	1
Função de perda	Erro quadrático médio
Regularização	L2 (lambda = 0,01)

3.2.4 Análise estatística

A grade amostral com os resultados de solo foi sobreposta aos mapas de ZM, compondo o conjunto de dados utilizado na análise estatística. Para cada ZM e atributo, foi realizada uma análise descritiva com médias e desvios padrão. Em seguida, as médias dos atributos foram comparadas por meio do teste de comparações múltiplas de Tukey ($\alpha = 0,05$), utilizando a

função `pairwise_tukeyhsd` da biblioteca `statsmodels` em Python 3 (<https://github.com/statsmodels/statsmodels/>).

Para avaliar o desempenho de cada método de definição das ZMs delimitadas (por meio da produtividade e os índices NDVI e VV/VH), foi utilizado o método de validação cruzada deixo-um-de-fora (LOOCV). A avaliação de cada abordagem foi realizada com base nos resultados das amostras de solo, considerando que o melhor método, em teoria, é aquele que proporciona a melhor estimativa dos atributos do solo. O objetivo é identificar a estratégia mais adequada para a realização de uma amostragem dirigida. No LOOCV, cada ponto da grade amostral de solo foi sucessivamente removido, e sua estimativa foi feita utilizando a média dos pontos restantes dentro da ZMs onde o ponto removido pertencia. Esse processo foi repetido até que todos os pontos fossem avaliados. Com base nos valores estimados dos atributos do solo e os valores amostrados em cada ponto correspondente, foi calculado o Erro Quadrático Médio (RMSE), conforme a equação (2):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2} \quad (5)$$

em que: \hat{x}_i representa o valor estimado do atributo do solo no ponto i ; x_i é o valor observado do atributo do solo no ponto i e n é o número de pontos amostrados.

Os valores de produtividade média padronizada, obtidos a partir dos mapas interpolados de produtividade, foram projetados sobre as ZMs delimitadas pelos índices NDVI e VV/VH. O objetivo dessa projeção foi avaliar a eficácia desses índices na identificação de zonas com alto e baixo potencial produtivo, representado pelo rendimento médio padronizado. Para isso, aplicou-se a estratégia de validação cruzada deixo-um-de-fora (LOOCV), na qual cada ponto do mapa de rendimento padronizado foi removido sucessivamente, e sua estimativa foi realizada com base na média dos pontos restantes dentro da ZM à qual pertencia. O erro foi quantificado por meio do cálculo do RMSE.

3.3 RESULTADOS E DISCUSSÃO

Na Tabela 5, são apresentados os parâmetros dos modelos teóricos ajustados sobre os mapas de produtividade, enquanto a Figura 3 exibe os mapas de tendências espaciais para as culturas de algodão e milho ao longo do período de estudo (2019-2023).

Tabela 5. Parâmetros do modelo teórico de semivariância ajustados à semivariância empírica dos dados de produtividade da área de estudo

Ano	Cultura	Modelo	Alcance (m)	C_0	$C_0 + C$	R^2	SDI (%)
2019	Algodão	Linear	313,15	0,19	0,27	0,41	70,37
2020	Algodão	Linear com patamar	480,92	0,12	0,31	0,76	38,71
2021	Algodão	Linear	298,86	0,05	0,08	0,68	61,33
2022	Algodão	Esférico	342,78	0,01	0,02	0,50	50,00
2023	Milho	Exponencial	126,58	0,17	0,52	0,34	32,70

Alcance (m); C_0 : Efeito Pepita; $C_0 + C$: Platô; R^2 : Coeficiente de determinação; SDI (%): Índice de Dependência Espacial

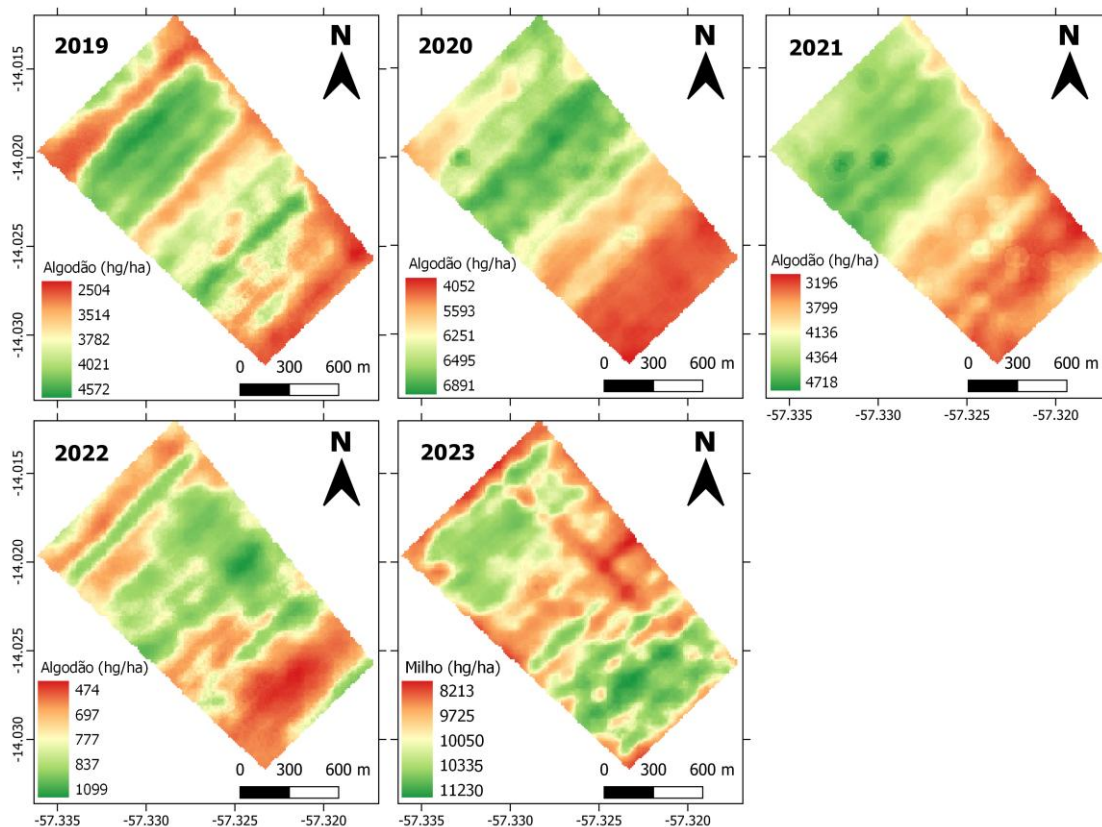


Figura 3. Mapas de produtividade interpolados por krigagem ordinária para cada ano (2019-2023).

Nos anos em que o algodão foi cultivado (2019-2022), observa-se um gradiente de produtividade no sentido noroeste-sudeste, com as maiores produtividades concentradas na região noroeste e os menores rendimentos no sudeste. Em 2023, a substituição do algodão pelo milho resultou em um padrão distinto, caracterizado por uma maior heterogeneidade na distribuição espacial da produtividade.

Na Figura 4, é apresentada a distribuição dos valores de produtividade para cada mapa interpolado, juntamente com o coeficiente de assimetria. Os resultados indicam que as distribuições apresentam uma assimetria levemente negativa, com coeficientes variando de -

0.19 a -0.88. Nesse caso, a média é um estimador adequado para o cálculo do mapa de produtividade relativa (%).

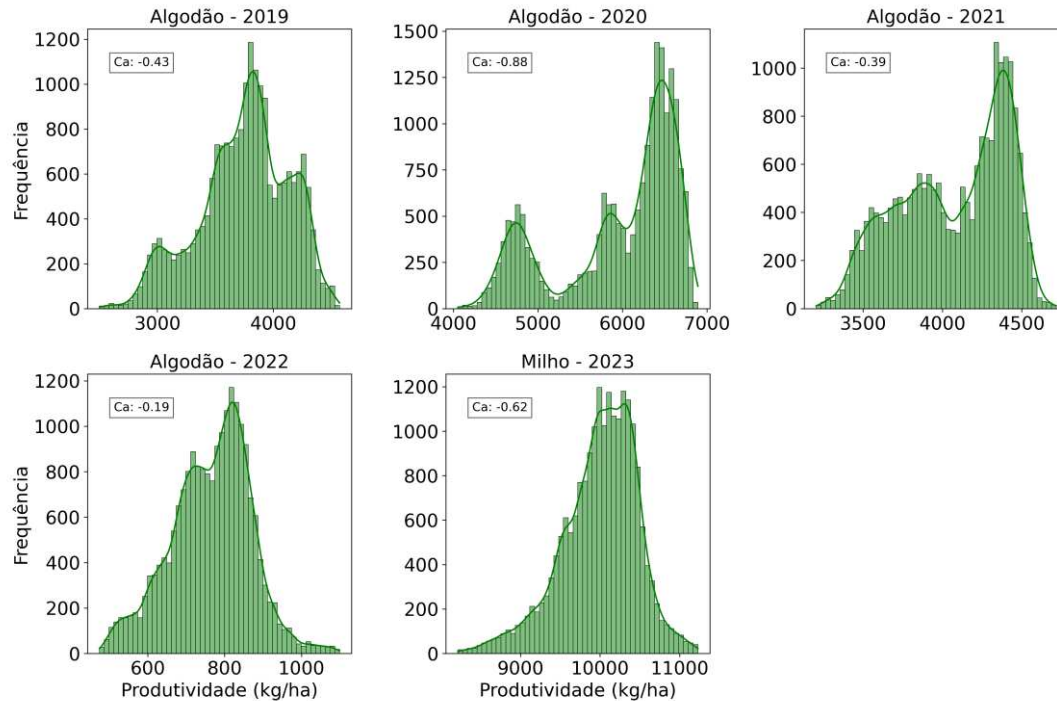


Figura 4. Histogramas dos mapas de produtividade interpolados por krigagem ordinária para cada ano com os valores de coeficiente de assimetria (Ca) (2019-2023).

A Tabela 6 apresenta um resumo da quantidade de imagens de satélite utilizadas no estudo, organizadas por sensor e ano de aquisição. Apesar da interrupção do fornecimento de imagens pelo Sentinel-1B em 23 de dezembro de 2021, o número de imagens disponíveis em 2022 permaneceu equivalente ao dos anos anteriores.

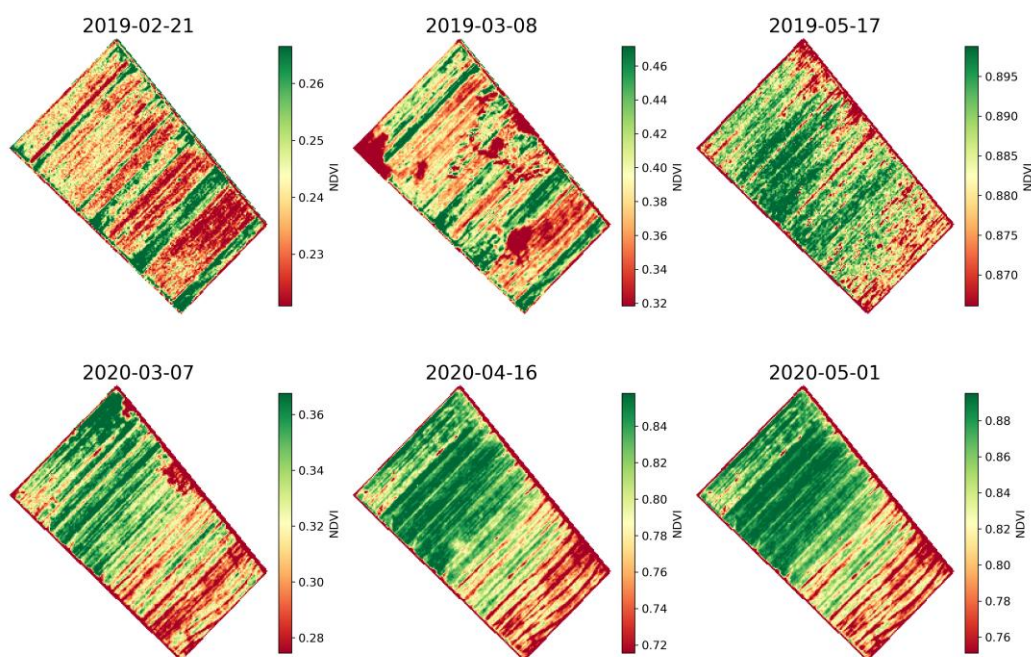
Tabela 6. Quantidade de imagens de satélite por sensor e ano de aquisição utilizadas no estudo

Sensores	Conjunto de dados	Ano						Total
		2018	2019	2020	2021	2022	2023	
Sentinel-1 C-SAR	COPERNICUS_S1_GRD	35	31	29	31	29	16	171
Sentinel-2 A/B MSI	S2_SR_HARMONIZED	-	3	3	3	3	3	15

O Sentinel-1 destaca-se por sua capacidade de aquisição em praticamente todas as condições climáticas, uma vez que seu sistema de sensoriamento ativo emite radiação eletromagnética de comprimentos de onda longos, permitindo a penetração através de nuvens e outros obstáculos atmosféricos. Essa característica é fundamental para o desenvolvimento de

métodos, pois garante maior previsibilidade na disponibilidade de imagens ao longo do período de análise. Por outro lado, o Sentinel-2 é um sensor óptico passivo que depende da luz solar para a aquisição de imagens. Seu sensor registra a radiação eletromagnética em comprimentos de onda curtos, que, ao serem refletidos pela superfície terrestre, são bloqueados pela presença de nuvens, impossibilitando a obtenção de imagens em condições de cobertura atmosférica densa. Essa limitação pode comprometer a disponibilidade de imagens para o monitoramento durante o desenvolvimento das culturas e delimitação de ZMs, especialmente em períodos de alta cobertura de nuvens. Um exemplo disso ocorreu em 2018, quando não foram encontradas imagens utilizáveis, ou seja, livres de interferência atmosférica, o que restringiu a análise nesse período.

Na Figura 5, são apresentadas as imagens de NDVI obtidas pelo Sentinel-2, destacando a variabilidade espacial e temporal do índice ao longo dos anos analisados. Com exceção de 2019, observa-se um gradiente nos valores de NDVI no sentido noroeste-sudeste, com as maiores concentrações na região noroeste e os menores valores no sudeste, um padrão similar ao observado nos mapas de produtividade. A única exceção a essa correspondência ocorreu em 2019, quando o mapa de produtividade revelou uma distribuição espacial mais heterogênea, enquanto as imagens de NDVI mantiveram o gradiente noroeste-sudeste, com os maiores valores no noroeste e os menores no sudeste.



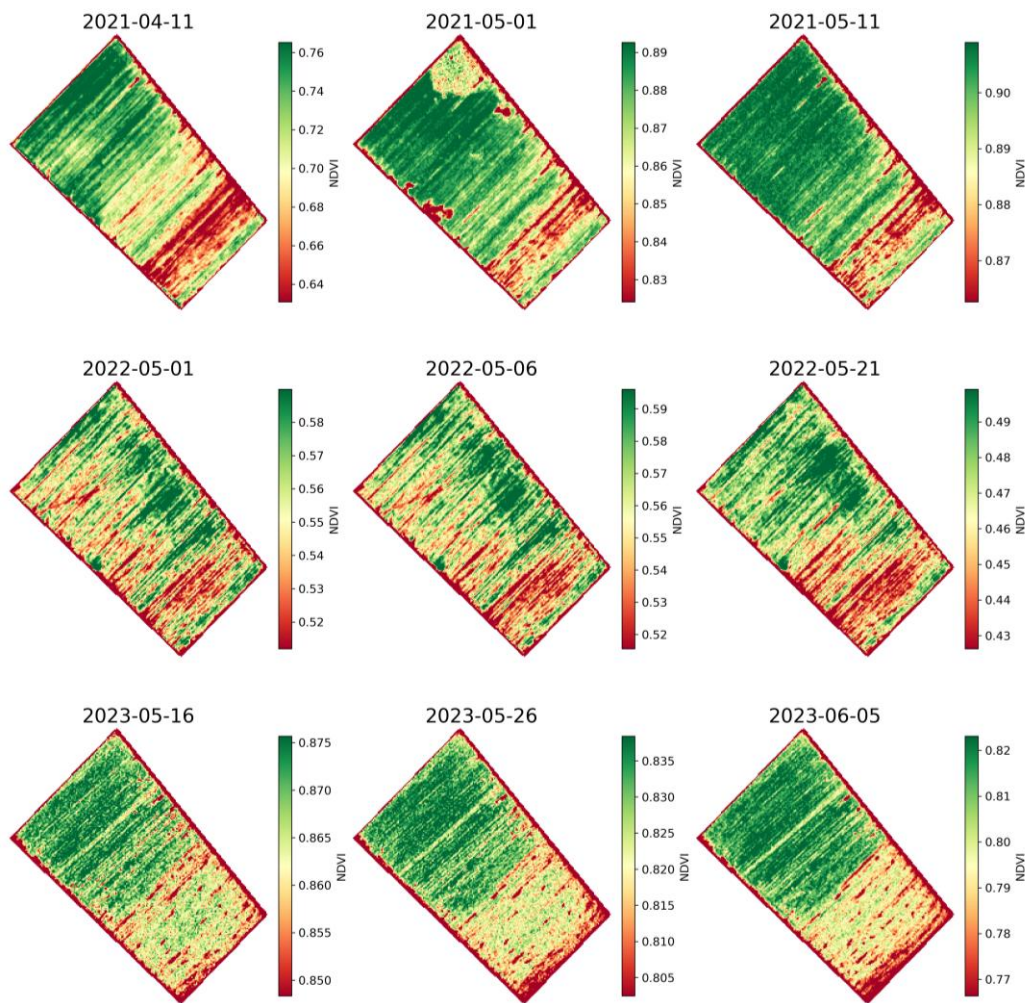
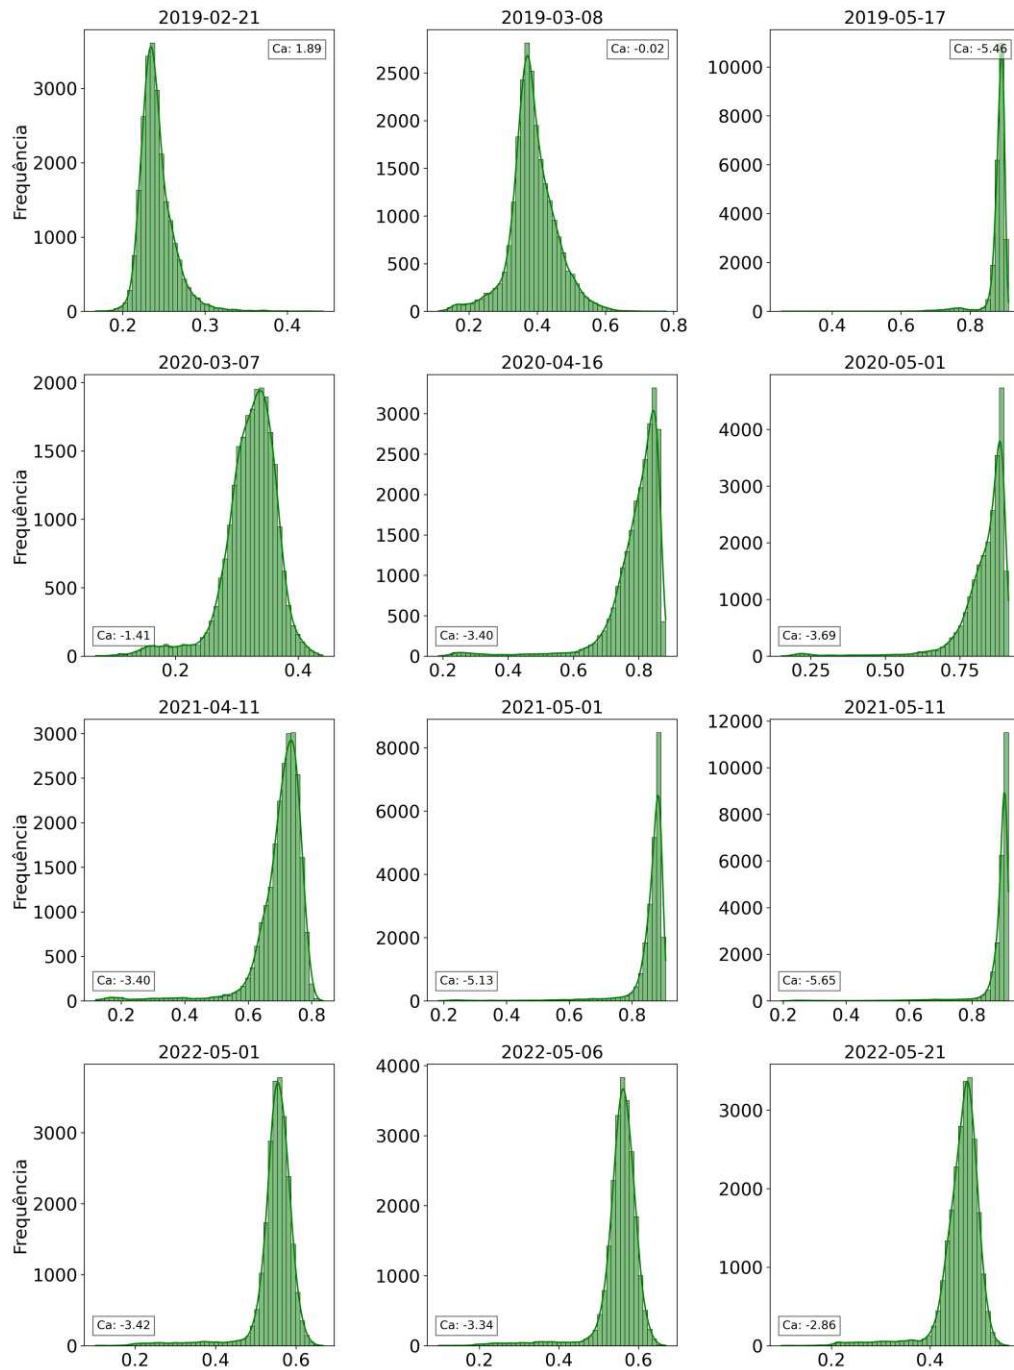


Figura 5. – Imagens de NDVI obtidas por meio do Sentinel-2 mostrando a variabilidade espacial e temporal do índice ao longo dos anos (2019-2023).

Na Figura 6, é apresentada a distribuição dos valores de NDVI para cada imagem, acompanhada do coeficiente de assimetria. Os resultados mostram que a maioria das distribuições apresenta uma assimetria negativa acentuada, com coeficientes inferiores -2 . Esse padrão sugere uma predominância de valores elevados de NDVI, característicos de áreas com maior biomassa, maior reflectância na banda do infravermelho próximo e maior absorção na banda do vermelho.

Por outro lado, a cauda alongada em direção a valores mais baixos reflete a presença de regiões com menor biomassa, menor reflectância no infravermelho próximo e maior reflectância na banda do vermelho, características típicas de áreas com menor cobertura vegetal ou estresse fisiológico. Uma exceção foi observada no ano de 2019, que apresentou heterogeneidade na distribuição dos coeficientes de assimetria, incluindo um valor positivo para

uma das imagens e um coeficiente próximo de zero para outra. Esse comportamento reforça a adequação do uso da mediana para o cálculo do NDVI padronizado (%), uma vez que este estimador é menos sensível a valores extremos e, portanto, fornece uma representação mais robusta da distribuição dos dados.



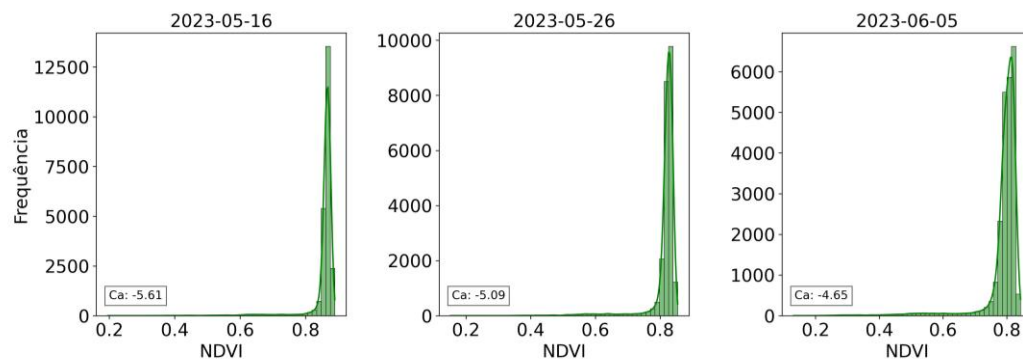


Figura 6. Histogramas das imagens NDVI para cada ano com os valores de coeficiente de assimetria (Ca) (2019-2023).

Na Figura 7 é apresentado o resultado da delimitação das ZM, com base nos mapas de produtividade e os índices NDVI e VV/VH. A variabilidade espacial e temporal observada nos mapas de produtividade e nas imagens NDVI foi analisada seguindo o método proposto por Blackmore (2000). A tendência espacial foi categorizada como Alto ou Baixo, dependendo de os valores estarem acima ou abaixo da média da produtividade padronizada (%). A variabilidade temporal, por sua vez, foi classificada como Estável ou Instável, com base em um limiar de estabilidade definido pelo coeficiente de variação, fixado em 20%. Para a variabilidade espacial e temporal na série temporal do índice SAR VV/VH foi avaliada segundo a metodologia desenvolvida por Gonçalves et al. (2025). Essa abordagem combina a aplicação de um algoritmo de *deep learning*, especificamente *autoencoders*, para compactação da série temporal, com um processo de agrupamento, permitindo a classificação dos pixels em grupos, resultando na delimitação das ZMs.

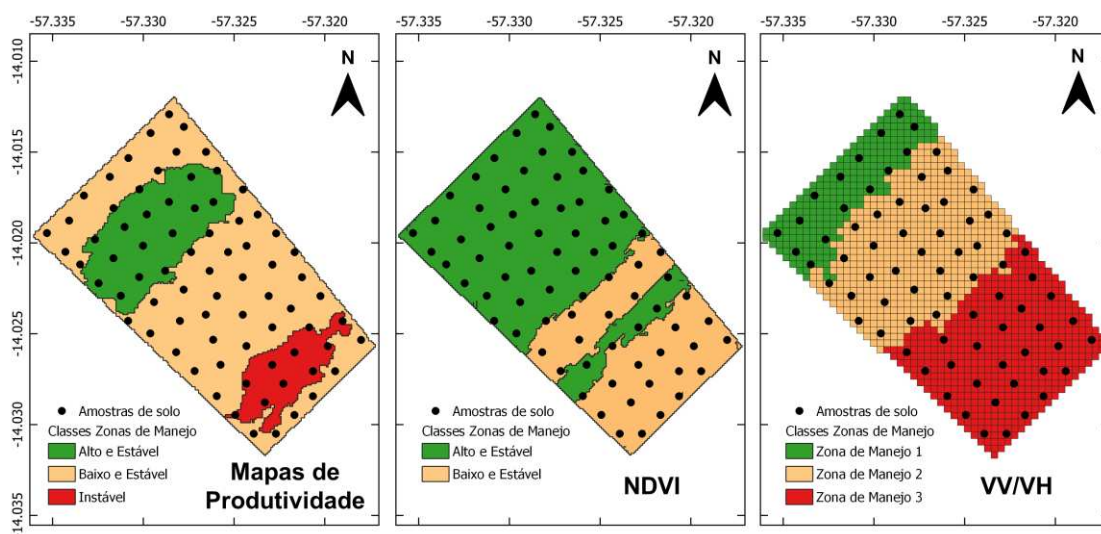


Figura 7. Zonas de manejo delimitadas com base no padrão de variabilidade espacial e temporal dos dados de produtividade e os índices NDVI e VV/VH.

As ZMs delimitadas pelos mapas de produtividade resultaram em três categorias: "Alto e Estável", "Baixo e Estável" e "Instável". Na Tabela 7 é possível observar que a média dos teores de Argila e potássio (K) apresentaram variação significativa entre as classes, sendo maior na classe "Alto e Estável" e menor na classe "Instável". Por outro lado, o pH, cálcio (Ca), magnésio (Mg), fósforo (P Mehlich e P Resina), capacidade de troca catiônica (CTC), matéria orgânica (MO) e saturação por bases (V) não apresentaram diferença significativa entre as médias.

A delimitação de ZMs a partir das imagens NDVI resultou em duas categorias: "Elevada e Estável" e "Baixa e Estável". Os Atributos Ca, K, MO, CTC e Argila apresentaram valores significativamente maiores na classe "Elevada e Estável". Em contrapartida, atributos como pH, Mg, fósforo (P Mehlich e P Resina) e V não apresentaram diferenças significativas entre as ZMs.

Tabela 7. Estatísticas descritivas e comparação dos valores médios dos atributos do solo para cada classe de zonas de manejo.

Variável utilizada para classificação	Atributo do solo	Elevada e Estável			Baixa e Estável			Instável				
		N	Média	Desvio padrão	N	Média	Desvio padrão	N	Média	Desvio padrão		
Produtividade	pH		5,56 ^a	0,04		5,57 ^a	0,03		5,63 ^a	0,08		
	Ca		2,94 ^a	0,10		2,89 ^a	0,06		2,77 ^a	0,15		
	Mg		1,50 ^a	0,07		1,52 ^a	0,04		1,57 ^a	0,10		
	K		0,25 ^a	0,01		0,22 ^{a,b}	0,01		0,19 ^b	0,01		
	P Mehlich	16	52	9	6,35 ^a	0,75	7,12 ^a	0,33	6,92 ^a	0,62		
	P Resina				21,12 ^a	1,83	22,37 ^a	1,20	20,44 ^a	1,52		
	MO				1,88 ^a	0,05	1,83 ^a	0,03	1,72 ^a	0,05		
	CTC				7,70 ^a	0,16	7,60 ^a	0,08	7,29 ^a	0,18		
	V				61,06 ^a	1,30	60,86 ^a	0,93	62,00 ^a	2,50		
Argila	55,63 ^a				0,68	48,09 ^b	1,10	36,58 ^c	1,13			
pH					5,57 ^a	0,03		5,59 ^a	0,04		-	-
Ca					2,96 ^a	0,06		2,75 ^b	0,07		-	-
Mg					1,53 ^a	0,04		1,51 ^a	0,05		-	-
NDVI	K		0,24 ^a	0,01		0,21 ^b	0,01		-	-		
	P_Mehlich		6,81 ^a	0,38		7,14 ^a	0,39		-	-		
	P_Resina		22,18 ^a	1,20		22,36 ^a	1,38		-	-		
	MO		1,89 ^a	0,03		1,73 ^b	0,03		-	-		
	CTC		7,75 ^a	0,09		7,60 ^b	0,09		-	-		
	V		60,92 ^a	0,91		61,25 ^a	1,27		-	-		
Argila		52,84 ^a	0,76		40,38 ^b	1,34		-	-			

pH: Acidez ativa na água; Ca²⁺: Cálcio; Mg²⁺: Magnésio; K⁺: Potássio; P: Fósforo; MO: Matéria Orgânica; CTC: Capacidade de Troca Catiônica; V: Saturação por bases; SD: Desvio padrão; CV: coeficiente de variação (%). Ca²⁺, Mg²⁺, K⁺ em cmolc/dm³. P Mehlich e P Resina em mg/dm³. MO, V e Argila em %. A média seguida pela mesma letra não é significativamente diferente, de acordo com o teste de comparações múltiplas de Tukey ($\alpha = 0,05$).

Por fim, a delimitação com base na série temporal do índice VV/VH, extraído de imagens SAR, destacou variações significativas para K, MO, CTC e Argila, com valores mais elevados na ZM 1 e menores na ZM 3. Os demais atributos não apresentaram diferenças significativas entre as zonas (Tabela 8).

Tabela 8. Estatísticas descritivas e comparação dos valores médios dos atributos do solo para cada classe de zonas de manejo.

Atributo do solo	Zona de Manejo 1			Zona de Manejo 2			Zona de Manejo 3		
	N	Média	Desvio padrão	N	Média	Desvio padrão	N	Média	Desvio padrão
pH		5,57 ^a	0,05		5,55 ^a	0,03		5,61 ^a	0,04
Ca		3,05 ^a	0,12		2,90 ^a	0,08		2,79 ^a	0,08
Mg		1,59 ^a	0,07		1,51 ^a	0,05		1,51 ^a	0,05
K		0,24 ^a	0,01		0,24 ^a	0,01		0,20 ^b	0,01
P_Mehlich	15	7,68 ^a	0,91	33	6,41 ^a	0,35	29	7,14 ^a	0,40
P_Resina		25,60 ^a	3,08		21,81 ^a	1,35		20,03 ^a	0,86
MO		1,89 ^a	0,05		1,90 ^a	0,04		1,72 ^b	0,03
CTC		8,01 ^a	0,14		7,68 ^a	0,11		7,24 ^b	0,09
V		60,80 ^a	1,60		60,27 ^a	1,09		62,03 ^a	1,28
Argila		54,84 ^a	0,85		53,37 ^a	0,62		39,18 ^b	1,12

pH: Acidez ativa na água; Ca²⁺: Cálcio; Mg²⁺: Magnésio; K⁺: Potássio; P: Fósforo; MO: Matéria Orgânica; CTC: Capacidade de Troca Catiônica; V: Saturação por bases; SD: Desvio padrão; CV: coeficiente de variação (%). Ca²⁺, Mg²⁺, K⁺ em cmolc/dm³. P Mehlich e P Resina em mg/dm³. MO, V e Argila em %. A média seguida pela mesma letra não é significativamente diferente, de acordo com o teste de comparações múltiplas de Tukey ($\alpha = 0,05$).

As condições climáticas ao longo do ciclo da cultura desempenham um papel determinante no desempenho produtivo, podendo suavizar a variabilidade do rendimento em situações de disponibilidade hídrica adequada (de la Casa et al., 2018). Áreas com menor teor de argila tendem a apresentar menor capacidade de retenção de umidade no solo, limitando a produtividade das culturas em anos de déficit hídrico (Reichert et al., 2009). Assim, a identificação de zonas de instabilidade pode estar associada ao baixo teor de argila, que limita a resiliência do sistema produtivo frente a condições hídricas adversas. Além disso, o mapa de produtividade média padronizada foi elaborado a partir de diferentes culturas, sendo algodão entre 2019 e 2022 e milho em 2023. Dessa forma, os atributos limitantes que influenciam a produtividade podem variar entre culturas, o que resulta em padrões distintos de variabilidade espacial, aumentando a área de instabilidade produtiva.

As ZMs delimitadas com base nos dados de NDVI, embora apresentem semelhanças com as delimitadas pelos mapas de produtividade, não identificaram áreas classificadas como instáveis. As imagens de NDVI revelam uma variabilidade espacial significativa entre os anos analisados, mas também mostram uma tendência consistente: uma parte do campo mantém

valores mais elevados de NDVI, enquanto outra apresenta valores mais baixos. Este padrão das imagens pode ter contribuído para o não surgimento de áreas com instabilidade.

Imagens SAR, como as do Sentinel-1, podem enfrentar limitações devido ao *speckle noise*, um dos principais fatores de interferência na interpretação de dados de radar. Esse ruído degrada a qualidade das imagens, dificultando tanto a análise visual direta quanto a identificação de padrões individuais, que são mais facilmente detectáveis em imagens multiespectrais com o uso de índices como o NDVI. Apesar de técnicas de pré-processamento, como *multi-look* ou filtros específicos para suavização do *speckle noise*, uma quantidade limitada de imagens SAR pode restringir a compreensão da variabilidade do retroespalhamento no campo. Isso, por sua vez, pode comprometer a associação dessa variabilidade às ZMs e reduzir a precisão na estimativa de atributos do solo. No entanto, a metodologia proposta por Gonçalves et al. (2025) utiliza a criação de perfis temporais em nível de pixels, com base em mais de 150 imagens SAR, para superar essas limitações. Com as ZMs delimitadas por essa abordagem, os autores demonstraram uma maior acurácia na representação da variabilidade dos atributos do solo em comparação com métodos tradicionais, como a amostragem convencional (uma amostra composta) e a amostragem em células (uma amostra composta por célula). Os resultados deste estudo, portanto, destacam o potencial do índice VV/VH e do método desenvolvido como uma ferramenta alternativa estratégica para implementação da agricultura de precisão, uma vez que se mostra capaz de mapear zonas com diferenças significativas nos atributos do solo.

Na Figura 8 são apresentados os valores de RMSE obtidos por meio da validação cruzada LOOCV, ilustrando a precisão das estimativas de atributos do solo com base nas ZMs definidas pelos índices VV/VH, NDVI e dados de rendimento. Na análise dos erros associados à estimativa dos atributos do solo, os três métodos mostraram desempenho similar para a maioria dos atributos. No entanto, o índice VV/VH destacou-se para os atributos CTC e Argila, alcançando os menores valores de RMSE em comparação com os outros índices, evidenciando sua superioridade nesses casos específicos.




Figura 8. RMSE dos métodos aplicados na delimitação das zonas de manejo na área em estudo.

A variabilidade observada nos mapas de produtividade e nas imagens de NDVI pode ser mais suscetível a fontes de variação externas aos atributos do solo, como erros nas estimativas dos monitores de produtividade, condições climáticas e práticas de manejo agrícola, quando comparada ao índice VV/VH. Os monitores de produtividade, especialmente para culturas como o algodão, apresentam limitações na manutenção da precisão das medições entre diferentes cultivares e sob condições de campo que variam espacial e temporalmente (Pelletier et al., 2019; Vories et al., 2019). Isso torna necessária uma calibração frequente, o que pode impactar negativamente a qualidade dos dados e a confiabilidade das estimativas de rendimento obtidas em campo. Além disso, as condições climáticas durante o ciclo da cultura desempenham um papel crucial no desempenho produtivo, influenciando diretamente a variabilidade da produtividade, especialmente em cenários de disponibilidade hídrica adequada, em que tais diferenças podem ser suavizadas. Nesse contexto, a construção de uma série histórica de mapas de produtividade é essencial para aumentar a confiabilidade na identificação e interpretação das tendências de variabilidade espacial e temporal.

O NDVI reflete principalmente a condição da biomassa e da cobertura vegetal, pois a luz no comprimento de onda do vermelho e infravermelho utilizada em seu cálculo possui capacidade limitada de penetração no dossel das culturas, restringindo sua sensibilidade às camadas mais superficiais da vegetação (Gitelson et al., 2014). Por essa razão, o NDVI pode ser influenciado por diversos fatores que afetam a biomassa e a cobertura vegetal, mas que não estão diretamente relacionados à variabilidade dos atributos do solo. Exemplos incluem a presença de plantas daninhas, ataques de pragas e doenças, além de práticas inadequadas de

manejo, como falhas na adubação ou no plantio, que resultam em densidade inadequada de sementes por metro, entre outros. Esses fatores podem alterar significativamente a condição da biomassa e da cobertura vegetal, reduzindo a precisão das imagens NDVI na estimativa de atributos do solo.

Por outro lado, o índice VV/VH, derivado de imagens SAR, apresenta sensibilidade tanto às variáveis biofísicas da vegetação quanto às propriedades do solo. Entre os parâmetros avaliados, destacam-se o teor de água das plantas, as propriedades geométricas do dossel da cultura, a rugosidade da superfície do dossel e do solo, além do teor de água do solo (Aubert et al., 2011; Li et al., 2022). A aquisição de imagens ao longo do ano para a construção de perfis temporais do índice VV/VH garante que muitas delas sejam coletadas em períodos de baixa biomassa ou mesmo de ausência total de vegetação, permitindo que o retroespalhamento seja influenciado quase exclusivamente pelas propriedades do solo. Além disso, El Hajj et al. (2018) demonstraram que, mesmo no pico de desenvolvimento da biomassa do milho, quando os valores de NDVI ultrapassam 0,7, a banda VV utilizada no cálculo do índice VV/VH conseguiu penetrar o dossel da cultura. Essas características torna o índice VV/VH menos suscetível a fontes de variação externas aos atributos do solo, como condições climáticas e práticas de manejo agrícolas inadequadas.

Na Figura 9 é apresentada a comparação entre as ZMs delimitadas pelos índices NDVI e VV/VH, projetadas sobre o mapa de produtividade média padronizada (%). Ambas as abordagens mostraram boa precisão na identificação das zonas de elevado e baixo potencial produtivo. A análise dos erros associados às estimativas de produtividade média padronizada revelou desempenhos semelhantes para os dois métodos, com RMSE de 4,27 para o NDVI e 4,32 para o índice VV/VH. Essa proximidade nos resultados evidencia que o índice VV/VH pode ser uma alternativa viável ao NDVI para estimar produtividade e identificar áreas com elevado e baixo potencial produtivo.

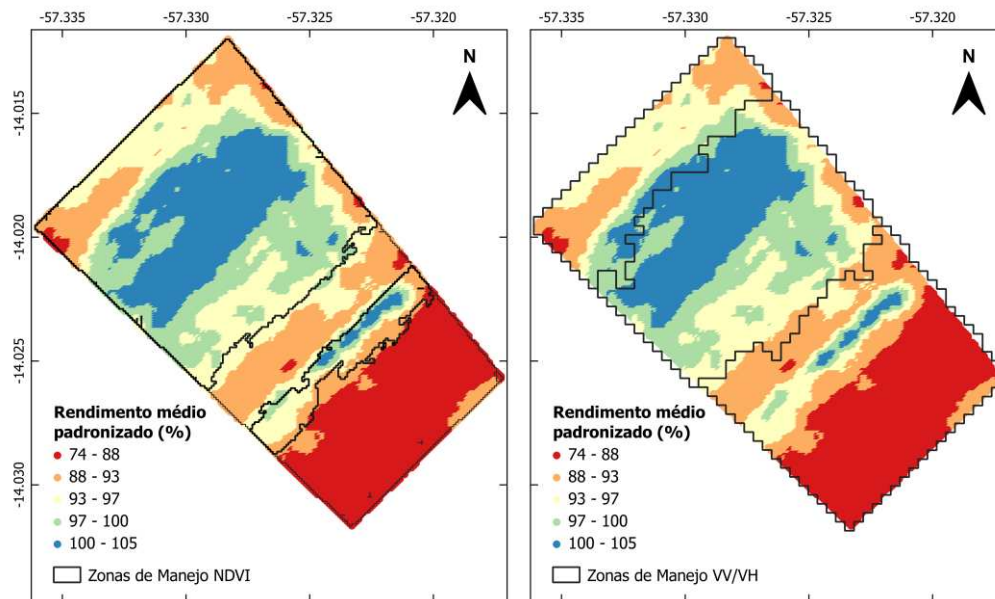


Figura 9. Zonas de manejo delimitadas pelos métodos baseados nos índices NDVI e VV/VH, sobrepostas ao mapa de produtividade padronizada (%).

3.4 CONCLUSÃO

As Zonas de Manejo (ZMs) delimitadas com base no índice VV/VH, mapas de rendimento e índice NDVI foram capazes de identificar zonas com diferenças significativas na média de diferentes atributos químicos e físicos do solo. A validação cruzada do deixo-um-de-fora (LOOCV) revelou que os três métodos apresentaram erros (RMSE) similares para a maioria dos atributos avaliados. Entretanto, o índice VV/VH destacou-se particularmente para o atributo Argila, obtendo os menores valores de RMSE em comparação aos outros métodos. Além disso, os valores de RMSE associados às estimativas de produtividade média padronizada revelou desempenhos semelhantes para os índices VV/VH e NDVI. Esses resultados destacam o potencial do índice SAR VV/VH como uma ferramenta precisa para a estimativa de atributos do solo, bem como para a identificação de regiões com alta e baixa produtividade.

3.5 REFERÊNCIAS

- Ali, A., Rondelli, V., Martelli, R., Falsone, G., Lupia, F., Barbanti, L., 2022. Management Zones Delineation through Clustering Techniques Based on Soils Traits, NDVI Data, and Multiple Year Crop Yields. *Agriculture* 12, 231. <https://doi.org/10.3390/agriculture12020231>
- Amaral, L.R., Oldoni, H., Baptista, G.M.M., Ferreira, G.H.S., Freitas, R.G., Martins, C.L., Cunha, I.A., Santos, A.F., 2024. Remote sensing imagery to predict soybean yield: a case study of vegetation indices contribution. *Precis Agric* 25, 2375–2393. <https://doi.org/10.1007/s11119-024-10174-5>
- Arnall, D.B., Abit, M.J.M., Taylor, R.K., Raun, W.R., 2016. Development of an NDVI-Based Nitrogen Rate Calculator for Cotton. *Crop Sci* 56, 3263–3271. <https://doi.org/10.2135/cropsci2016.01.0049>
- Aubert, M., Baghdadi, N., Zribi, M., Douaoui, A., Loumagne, C., Baup, F., El Hajj, M., Garrigues, S., 2011. Analysis of TerraSAR-X data sensitivity to bare soil moisture, roughness, composition and soil crust. *Remote Sens Environ* 115, 1801–1810. <https://doi.org/10.1016/j.rse.2011.02.021>
- Azizi, K., Garosi, Y., Ayoubi, S., Tajik, S., 2023. Integration of Sentinel-1/2 and topographic attributes to predict the spatial distribution of soil texture fractions in some agricultural soils of western Iran. *Soil Tillage Res* 229, 105681. <https://doi.org/10.1016/j.still.2023.105681>
- Balenzano, A., Mattia, F., Satalino, G., Lovergine, F.P., Palmisano, D., Peng, J., Marzahn, P., Wegmüller, U., Cartus, O., Dąbrowska-Zielińska, K., Musial, J.P., Davidson, M.W.J., Pauwels, V.R.N., Cosh, M.H., McNairn, H., Johnson, J.T., Walker, J.P., Yueh, S.H., Entekhabi, D., Kerr, Y.H., Jackson, T.J., 2021. Sentinel-1 soil moisture at 1 km resolution: a validation study. *Remote Sens Environ* 263, 112554. <https://doi.org/10.1016/j.rse.2021.112554>
- Barbosa Júnior, M.R., Moreira, B.R. de A., Carreira, V. dos S., Brito Filho, A.L. de, Trentin, C., Souza, F.L.P. de, Tedesco, D., Setiyono, T., Flores, J.P., Ampatzidis, Y., Silva, R.P. da, Shiratsuchi, L.S., 2024. Precision agriculture in the United States: A comprehensive meta-review inspiring further research, innovation, and adoption. *Comput Electron Agric* 221, 108993. <https://doi.org/10.1016/j.compag.2024.108993>
- Basso, B., Fiorentino, C., Cammarano, D., Cafiero, G., Dardanelli, J., 2012. Analysis of rainfall

distribution on spatial and temporal patterns of wheat yield in Mediterranean environment. *European Journal of Agronomy* 41, 52–65. <https://doi.org/10.1016/j.eja.2012.03.007>

Bazzi, H., Baghdadi, N., El Hajj, M., Zribi, M., Minh, D.H.T., Ndikumana, E., Courault, D., Belhouchette, H., 2019. Mapping Paddy Rice Using Sentinel-1 SAR Time Series in Camargue, France. *Remote Sens (Basel)* 11, 887. <https://doi.org/10.3390/rs11070887>

Blackmore, S., 2000. The interpretation of trends from multiple yield maps. *Comput Electron Agric* 26, 37–51. [https://doi.org/10.1016/S0168-1699\(99\)00075-7](https://doi.org/10.1016/S0168-1699(99)00075-7)

Blackmore, S., Godwin, R.J., Fountas, S., 2003. The Analysis of Spatial and Temporal Trends in Yield Map Data over Six Years. *Biosyst Eng* 84, 455–466. [https://doi.org/10.1016/S1537-5110\(03\)00038-2](https://doi.org/10.1016/S1537-5110(03)00038-2)

Bottega, E.L., Safanelli, J.L., Zeraatpisheh, M., Amado, T.J.C., Queiroz, D.M. de, Oliveira, Z.B. de, 2022. Site-Specific Management Zones Delineation Based on Apparent Soil Electrical Conductivity in Two Contrasting Fields of Southern Brazil. *Agronomy* 12, 1390. <https://doi.org/10.3390/agronomy12061390>

Brock, A., Brouder, S.M., Blumhoff, G., Hofmann, B.S., 2005. Defining Yield-Based Management Zones for Corn-Soybean Rotations. *Agron J* 97, 1115–1128. <https://doi.org/10.2134/agronj2004.0220>

Chaudhary, S.K., Srivastava, P.K., Gupta, D.K., Kumar, P., Prasad, R., Pandey, D.K., Das, A.K., Gupta, M., 2022. Machine learning algorithms for soil moisture estimation using Sentinel-1: Model development and implementation. *Advances in Space Research* 69, 1799–1812. <https://doi.org/10.1016/j.asr.2021.08.022>

Damian, J.M., Pias, O.H. de C., Cherubin, M.R., Fonseca, A.Z. da, Fornari, E.Z., Santi, A.L., 2020. Applying the NDVI from satellite images in delimiting management zones for annual crops. *Sci Agric* 77. <https://doi.org/10.1590/1678-992x-2018-0055>

de la Casa, A., Ovando, G., Bressanini, L., Martínez, J., Díaz, G., Miranda, C., 2018. Soybean crop coverage estimation from NDVI images with different spatial resolution to evaluate yield variability in a plot. *ISPRS Journal of Photogrammetry and Remote Sensing* 146, 531–547. <https://doi.org/10.1016/j.isprsjprs.2018.10.018>

El Hajj, M., Baghdadi, N., Bazzi, H., Zribi, M., 2018. Penetration Analysis of SAR Signals in the C and L Bands for Wheat, Maize, and Grasslands. *Remote Sens (Basel)* 11, 31. <https://doi.org/10.3390/rs11010031>

Esteves, C., Fangueiro, D., Braga, R.P., Martins, M., Botelho, M., Ribeiro, H., 2022. Assessing the Contribution of ECa and NDVI in the Delineation of Management Zones in a Vineyard. *Agronomy* 12, 1331. <https://doi.org/10.3390/agronomy12061331>

Frison, P.-L., Fruneau, B., Kmiha, S., Soudani, K., Dufrêne, E., Toan, T. Le, Koleck, T., Villard, L., Mougín, E., Rudant, J.-P., 2018. Potential of Sentinel-1 Data for Monitoring Temperate Mixed Forest Phenology. *Remote Sens (Basel)* 10, 2049. <https://doi.org/10.3390/rs10122049>

Garosi, Y., Ayoubi, S., Nussbaum, M., Sheklabadi, M., Nael, M., Kimiaee, I., 2022. Use of the time series and multi-temporal features of Sentinel-1/2 satellite imagery to predict soil inorganic and organic carbon in a low-relief area with a semi-arid environment. *Int J Remote Sens* 43, 6856–6880. <https://doi.org/10.1080/01431161.2022.2147037>

Gitelson, A.A., Peng, Y., Huemmrich, K.F., 2014. Relationship between fraction of radiation absorbed by photosynthesizing maize and soybean canopies and NDVI from remotely sensed data taken at close range and from MODIS 250m resolution data. *Remote Sens Environ* 147, 108–120. <https://doi.org/10.1016/j.rse.2014.02.014>

Hair, J.F., B.W.C., B.B.J., A.R.E., & T.R.L., 2006. *Multivariate data analysis* 6th Edition. Pearson Prentice Hall, New Jersey.

Ju, J., Roy, D.P., 2008. The availability of cloud-free Landsat ETM+ data over the conterminous United States and globally. *Remote Sens Environ* 112, 1196–1211. <https://doi.org/10.1016/j.rse.2007.08.011>

Kaushik, S.K., Mishra, V.N., Punia, M., Diwate, P., Sivasankar, T., Soni, A.K., 2021. Crop Health Assessment Using Sentinel-1 SAR Time Series Data in a Part of Central India. *Remote Sens Earth Syst Sci* 4, 217–234. <https://doi.org/10.1007/s41976-021-00064-z>

Kendall, H., Clark, B., Li, W., Jin, S., Jones, Glyn.D., Chen, J., Taylor, J., Li, Z., Frewer, Lynn.J., 2022. Precision agriculture technology adoption: a qualitative study of small-scale commercial “family farms” located in the North China Plain. *Precis Agric* 23, 319–351.

<https://doi.org/10.1007/s11119-021-09839-2>

Lasko, K., Vadrevu, K.P., Tran, V.T., Justice, C., 2018. Mapping Double and Single Crop Paddy Rice With Sentinel-1A at Varying Spatial Scales and Polarizations in Hanoi, Vietnam. *IEEE J Sel Top Appl Earth Obs Remote Sens* 11, 498–512. <https://doi.org/10.1109/JSTARS.2017.2784784>

Li, J., Li, C., Xu, W., Feng, H., Zhao, F., Long, H., Meng, Y., Chen, W., Yang, H., Yang, G., 2022. Fusion of optical and SAR images based on deep learning to reconstruct vegetation NDVI time series in cloud-prone regions. *International Journal of Applied Earth Observation and Geoinformation* 112, 102818. <https://doi.org/10.1016/j.jag.2022.102818>

Macedo, F.L., Nóbrega, H., de Freitas, J.G.R., Ragonezi, C., Pinto, L., Rosa, J., Pinheiro de Carvalho, M.A.A., 2023. Estimation of Productivity and Above-Ground Biomass for Corn (*Zea mays*) via Vegetation Indices in Madeira Island. *Agriculture* 13, 1115. <https://doi.org/10.3390/agriculture13061115>

Maresma, A., Chamberlain, L., Tagarakis, A., Kharel, T., Godwin, G., Czymbek, K.J., Shields, E., Ketterings, Q.M., 2020. Accuracy of NDVI-derived corn yield predictions is impacted by time of sensing. *Comput Electron Agric* 169, 105236. <https://doi.org/10.1016/j.compag.2020.105236>

McFadden, J., Njuki, E., Griffin, T., 2023. Precision Agriculture in the Digital Era: Recent Adoption on U.S. Farms.

Mirzaeitalarposhti, R., Shafizadeh-Moghadam, H., Taghizadeh-Mehrjardi, R., Demyan, M.S., 2022. Digital Soil Texture Mapping and Spatial Transferability of Machine Learning Models Using Sentinel-1, Sentinel-2, and Terrain-Derived Covariates. *Remote Sens (Basel)* 14, 5909. <https://doi.org/10.3390/rs14235909>

Moharana, P.C., Jena, R.K., Pradhan, U.K., Nogiya, M., Tailor, B.L., Singh, R.S., Singh, S.K., 2020. Geostatistical and fuzzy clustering approach for delineation of site-specific management zones and yield-limiting factors in irrigated hot arid environment of India. *Precis Agric* 21, 426–448. <https://doi.org/10.1007/s11119-019-09671-9>

Mullissa, A., Vollrath, A., Odongo-Braun, C., Slagter, B., Balling, J., Gou, Y., Gorelick, N., Reiche, J., 2021. Sentinel-1 SAR Backscatter Analysis Ready Data Preparation in Google Earth

Engine. *Remote Sens (Basel)* 13, 1954. <https://doi.org/10.3390/rs13101954>

Pelletier, M.G., Wanjura, J.D., Holt, G.A., 2019. Man-Machine-Interface Software Design of a Cotton Harvester Yield Monitor Calibration System. *AgriEngineering* 1, 511–522. <https://doi.org/10.3390/agriengineering1040037>

Peralta, N.R., Costa, J.L., 2013. Delineation of management zones with soil apparent electrical conductivity to improve nutrient management. *Comput Electron Agric* 99, 218–226. <https://doi.org/10.1016/j.compag.2013.09.014>

Pereira, G.W., Valente, D.S.M., Queiroz, D.M. de, Coelho, A.L. de F., Costa, M.M., Grift, T., 2022. Smart-Map: An Open-Source QGIS Plugin for Digital Mapping Using Machine Learning Techniques and Ordinary Kriging. *Agronomy* 12, 1350. <https://doi.org/10.3390/agronomy12061350>

Queiroz, D.M. de, Coelho, A.L. de F., Valente, D.S.M., Schueller, J.K., 2020. Sensors Applied to Digital Agriculture: A Review. *REVISTA CIÊNCIA AGRONÔMICA* 51. <https://doi.org/10.5935/1806-6690.20200086>

Reichert, J.M., Albuquerque, J.A., Kaiser, D.R., Reinert, D.J., Urach, F.L., Carlesso, R., 2009. Estimation of water retention and availability in soils of Rio Grande do Sul. *Rev Bras Cienc Solo* 33, 1547–1560. <https://doi.org/10.1590/S0100-06832009000600004>

Rossini, P.R., Ciampitti, I.A., Hefley, T., Patrignani, A., 2021. A soil moisture-based framework for guiding the number and location of soil moisture sensors in agricultural fields. *Vadose Zone Journal* 20. <https://doi.org/10.1002/vzj2.20159>

Shashikumar, B.N., Kumar, S., George, K.J., Singh, A.K., 2023. Soil variability mapping and delineation of site-specific management zones using fuzzy clustering analysis in a Mid-Himalayan Watershed, India. *Environ Dev Sustain* 25, 8539–8559. <https://doi.org/10.1007/s10668-022-02411-6>

Solos Embrapa, 2013. Sistema brasileiro de classificação de solos. Centro Nacional de Pesquisa de Solos: Rio de Janeiro 3.

Soussi, A., Zero, E., Sacile, R., Trincherro, D., Fossa, M., 2024. Smart Sensors and Smart Data for Precision Agriculture: A Review. *Sensors* 24, 2647. <https://doi.org/10.3390/s24082647>

Speranza, E.A., Naime, J. de M., Vaz, C.M.P., Santos, J.C.F. dos, Inamasu, R.Y., Lopes, I. de O.N., Queirós, L.R., Rabelo, L.M., Jorge, L.A. de C., Chagas, S. das, Schelp, M.X., Vecchi, L., 2023. Delineating Management Zones with Different Yield Potentials in Soybean–Corn and Soybean–Cotton Production Systems. *AgriEngineering* 5, 1481–1497. <https://doi.org/10.3390/agriengineering5030092>

Valente, D.S.M., Pereira, G.W., de Queiroz, D.M., Zandonadi, R.S., Amaral, L.R. do, Bottega, E.L., Costa, M.M., de Freitas Coelho, A.L., Grift, T., 2024. Accuracy of Various Sampling Techniques for Precision Agriculture: A Case Study in Brazil. *Agriculture* 14, 2198. <https://doi.org/10.3390/agriculture14122198>

Valente, D.S.M., Queiroz, D.M. de, Pinto, F. de A. de C., Santos, N.T., Santos, F.L., 2012. Definition of management zones in coffee production fields based on apparent soil electrical conductivity. *Sci Agric* 69, 173–179. <https://doi.org/10.1590/S0103-90162012000300001>

Veloso, A., Mermoz, S., Bouvet, A., Le Toan, T., Planells, M., Dejoux, J.-F., Ceschia, E., 2017. Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications. *Remote Sens Environ* 199, 415–426. <https://doi.org/10.1016/j.rse.2017.07.015>

Vories, E.D., Jones, A.S., Meeks, C.D., Stevens, W.E., 2019. Variety Effects on Cotton Yield Monitor Calibration. *Appl Eng Agric* 35, 345–354. <https://doi.org/10.13031/aea.13144>

Webster, R., Oliver, M.A., 1992. Sample adequately to estimate variograms of soil properties. *Journal of Soil Science* 43, 177–192. <https://doi.org/10.1111/j.1365-2389.1992.tb00128.x>

Wei, J., Huang, W., Li, Z., Sun, L., Zhu, X., Yuan, Q., Liu, L., Cribb, M., 2020. Cloud detection for Landsat imagery by combining the random forest and superpixels extracted via energy-driven sampling segmentation approaches. *Remote Sens Environ* 248, 112005. <https://doi.org/10.1016/j.rse.2020.112005>

Yang, R.-M., Guo, W.-W., 2019. Modelling of soil organic carbon and bulk density in invaded coastal wetlands using Sentinel-1 imagery. *International Journal of Applied Earth Observation and Geoinformation* 82, 101906. <https://doi.org/10.1016/j.jag.2019.101906>

Zhou, Z., Ding, Y., Liu, S., Wang, Y., Fu, Q., Shi, H., 2022. Estimating the Applicability of NDVI and SIF to Gross Primary Productivity and Grain-Yield Monitoring in China. *Remote Sens (Basel)* 14, 3237. <https://doi.org/10.3390/rs14133237>

4. CONCLUSÃO GERAL

Com resultados obtidos neste trabalho, pôde-se concluir que:

1. A combinação do índice VV/VH com o algoritmo de *deep learning autoencoders* para a delimitação de Zonas de Manejo (ZMs) proporcionou estimativas mais precisas dos atributos do solo.
2. A estratégia com base no índice VV/VH com o algoritmo de *deep learning autoencoders* para a delimitação de ZM superou o método convencional de amostragem do solo (uma amostra composta) e, em muitos casos, o método de amostragem do solo por células.
3. As ZMs delimitadas pela estratégia que combina o índice VV/VH com o algoritmo de *deep learning autoencoders* apresentaram desempenho semelhante ao NDVI e aos mapas de produtividade na estimativa da maioria dos atributos do solo analisados. No entanto, para o atributo argila, essa abordagem superou significativamente esses métodos.
4. A eficácia do índice VV/VH é similar ao NDVI na identificação de zonas de alta e baixa produtividade.
5. O índice VV/VH do Sentinel-1 é uma alternativa viável para a delimitação de ZMs.