



MAPEAMENTO DE TELAS ANTIGRANIZO EM POMARES DE MAÇÃ EM VACARIA - RS

Vinícius Fernandes da Silva; Luciano Gebler; Marcia Helena Galina Dompieri

Nº 25508

RESUMO - O uso crescente de telas antigranizo em pomares de maçã tem contribuído na mitigação dos impactos de eventos climáticos extremos, como granizo e geadas, especialmente em regiões de elevada vulnerabilidade climática. No entanto, a expansão dessas estruturas demanda metodologias eficazes para seu monitoramento em larga escala, com foco tanto na gestão agrônômica como ambiental. O presente estudo teve como objetivo desenvolver e testar uma abordagem de sensoriamento remoto associada a técnicas de aprendizado de máquina para mapear telas antigranizo no município de Vacaria, no estado do Rio Grande do Sul. Foram utilizadas imagens do sensor Sentinel-2, considerando as bandas espectrais azul, verde, vermelho e infravermelho próximo, processadas na plataforma Google Earth Engine. Foi utilizada a segmentação por K-means e foram empregados classificadores Random Forest, tanto na abordagem pixel a pixel como baseada em objetos. A amostragem contou com oitocentos pontos, divididos entre treinamento e validação e a avaliação da acurácia foi realizada por meio de matrizes de confusão e do índice Kappa. A abordagem pixel a pixel apresentou um desempenho superior, com índice Kappa de 0.67, uma acurácia global de 0.76 e de 0.95 para a classe de cultivos com tela. Conclui-se que os resultados demonstram a viabilidade técnica da metodologia para mapeamento de estruturas agrícolas plásticas.

Palavras-chave: Agricultura de precisão; aprendizagem de máquina; mapeamento agrícola; Random Forest

ABSTRACT – The growing use of anti-hail nets in apple orchards has contributed to mitigating the impacts of extreme weather events, such as hailstorms and frosts, particularly in regions with high climate vulnerability. However, the expansion of these protective structures requires effective methodologies for large-scale monitoring, with a focus on both agronomic and environmental management. This study aimed to develop and test a remote sensing approach combined with machine learning techniques to map anti-hail nets in the municipality of Vacaria, located in the state of Rio Grande do Sul, Brazil. Sentinel-2 imagery was used, incorporating the blue, green, red, and near-infrared spectral bands, processed through the Google Earth Engine platform. K-means



segmentation was applied, and Random Forest classifiers were implemented using both pixel-based and object-based classification approaches. A total of 800 sample points were used, split between training and validation, and classification accuracy was assessed using confusion matrices and the Kappa index. The pixel-based approach outperformed the object-based classification, yielding a Kappa index of 0.67, an overall accuracy of 0.76, and a class accuracy of 0.95 for net-covered orchards. The results confirm the technical feasibility of the proposed methodology for mapping plastic agricultural structures.

Keywords: Agricultural mapping; machine learning; precision agriculture; *Random Forest*; remote sensing

1- INTRODUÇÃO

A utilização de estruturas de proteção, como as telas antigranizo, consolidou-se como uma prática importante na fruticultura moderna, especialmente em regiões sujeitas a eventos climáticos extremos, como granizo e geadas. Essas estruturas desempenham papel duplo: além da proteção física contra danos mecânicos, contribuem para a estabilização do microclima, promovendo maior previsibilidade na produtividade e na qualidade dos frutos.

No Sul do Brasil, destaca-se o município de Vacaria/RS, um dos principais pólos da fruticultura temperada nacional. A relevância desse território está associada tanto à sua expressiva área plantada quanto à frequência de intempéries climáticas severas, como o granizo, conforme observado por Lazzarotto e Fioravanço (2020). A recorrência desse fenômeno impõe riscos significativos à viabilidade econômica da produção de maçã, demandando medidas mitigadoras como o uso de telas ou a contratação de seguro agrícola. A escolha de Vacaria como área piloto, portanto, é estratégica: além de sua importância produtiva, representa cenário típico dos desafios enfrentados pela fruticultura em regiões de elevada exposição climática.

Sob a perspectiva agrônômica, diversos estudos têm evidenciado os efeitos positivos das telas antigranizo sobre atributos fisiológicos e produtivos das plantas. Amarante et al. (2007), por exemplo, ao avaliarem macieiras ‘Gala’ e ‘Fuji’ sob proteção no Sul do Brasil, relataram melhoria no peso dos frutos, aumento na área foliar específica e redução de doenças e danos por insolação, embora tenham também registrado impactos negativos em parâmetros como cor da casca e sólidos solúveis. Resultados semelhantes foram encontrados por Li et al. (2024), que associaram tempos ótimos de cobertura a ganhos em qualidade e fisiologia das plantas. Tais evidências reforçam a importância de se monitorar, em escala territorial, a presença e a eficácia dessas coberturas.



Nesse contexto, tecnologias de sensoriamento remoto (SR) têm se destacado como ferramentas promissoras para o mapeamento e monitoramento dessas estruturas. O uso de imagens orbitais, especialmente com dados multitemporais, permite detectar áreas protegidas por plásticos agrícolas com boa acurácia, especialmente por meio de índices espectrais específicos sensíveis aos materiais das coberturas (Blanco et al., 2018, Zhang et al., 2022).

Adicionalmente, a aplicação de técnicas de aprendizado de máquina, como *Random Forest* e redes neurais convolucionais profundas, tem elevado a precisão das classificações e viabilizado a detecção automatizada em larga escala (Dimitrovski et al., 2021; Chen et al., 2023). A integração dessas ferramentas permite não apenas a identificação da presença das telas, mas também o acompanhamento temporal de sua instalação e substituição, o que é crucial para análises agronômicas, econômicas e ambientais.

Contudo, vale salientar que o avanço do uso de plásticos na agricultura levanta preocupações ambientais crescentes, especialmente relacionadas ao acúmulo de microplásticos nos solos e à emissão de gases de efeito estufa (GEE) (Liu et al., 2022). Essas externalidades negativas ressaltam a necessidade de estratégias sustentáveis, como o uso de materiais biodegradáveis, programas de reciclagem e o próprio monitoramento geoespacial das áreas protegidas, que pode orientar ações de gestão ambiental mais eficazes (Hofmann et al., 2023).

Diante desse contexto, este trabalho tem por objetivo aplicar técnicas de sensoriamento remoto e aprendizado de máquina para identificar e mapear telas antigranizo em pomares de macieira no município de Vacaria/RS. A proposta visa testar a acurácia de diferentes abordagens classificatórias, apoiando estratégias de monitoramento em regiões altamente expostas a riscos climáticos e pressionadas por exigências de sustentabilidade (Lazzarotto e Fioravanço, 2020).

2- ÁREA DE ESTUDO, DADOS E METODOLOGIA

2.1- Área de estudo

Em 2023, a produção brasileira de maçã alcançou aproximadamente 1,2 milhão de toneladas, segundo dados da Produção Agrícola Municipal (IBGE, 2024). O cultivo da fruta é fortemente concentrado na região Sul, com destaque absoluto para os estados do Rio Grande do Sul (RS) e Santa Catarina (SC), que juntos responderam por cerca de 97% do volume total produzido. Os estados do Paraná, Minas Gerais e São Paulo contribuíram com os 3% restantes, em 2023, como evidenciado na Figura 1A. A análise da média de produção entre 2019 e 2023 (Figura 1B) reforça essa concentração regional e a estabilidade relativa dos volumes produzidos ao longo do quinquênio.

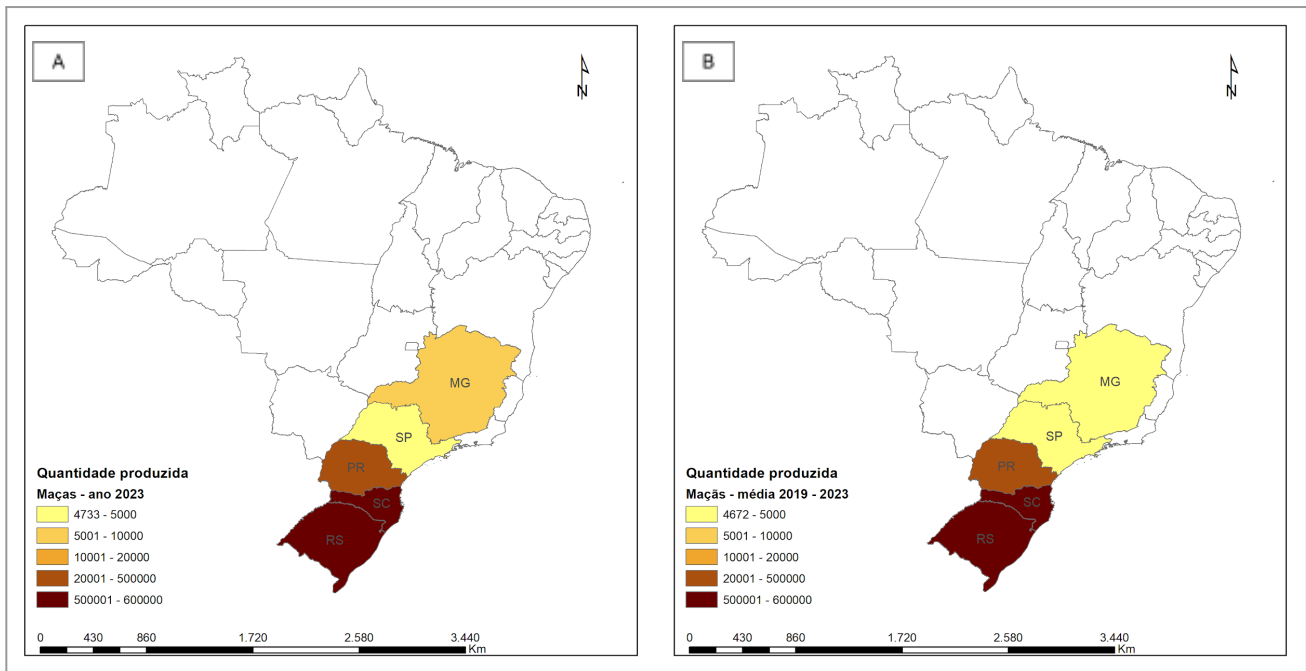


Figura 1 - Quantidade (t) de maçãs produzidas por estado. A: Em 2023; B: Média entre 2019-2023

No contexto municipal, destaca-se o município de Vacaria/RS, localizado na Serra Gaúcha, como um dos principais pólos da fruticultura temperada brasileira. Em 2023, o município foi responsável por aproximadamente 214 mil toneladas de maçã, o que representa cerca de 40% da produção estadual e quase 18% da produção nacional. Esse desempenho expressivo o posiciona como um pólo produtivo e tecnológico da cadeia da maçã no Brasil. Conforme ilustrado nas Figuras 2A e 2B, Vacaria lidera com ampla margem em relação aos demais municípios produtores do estado.

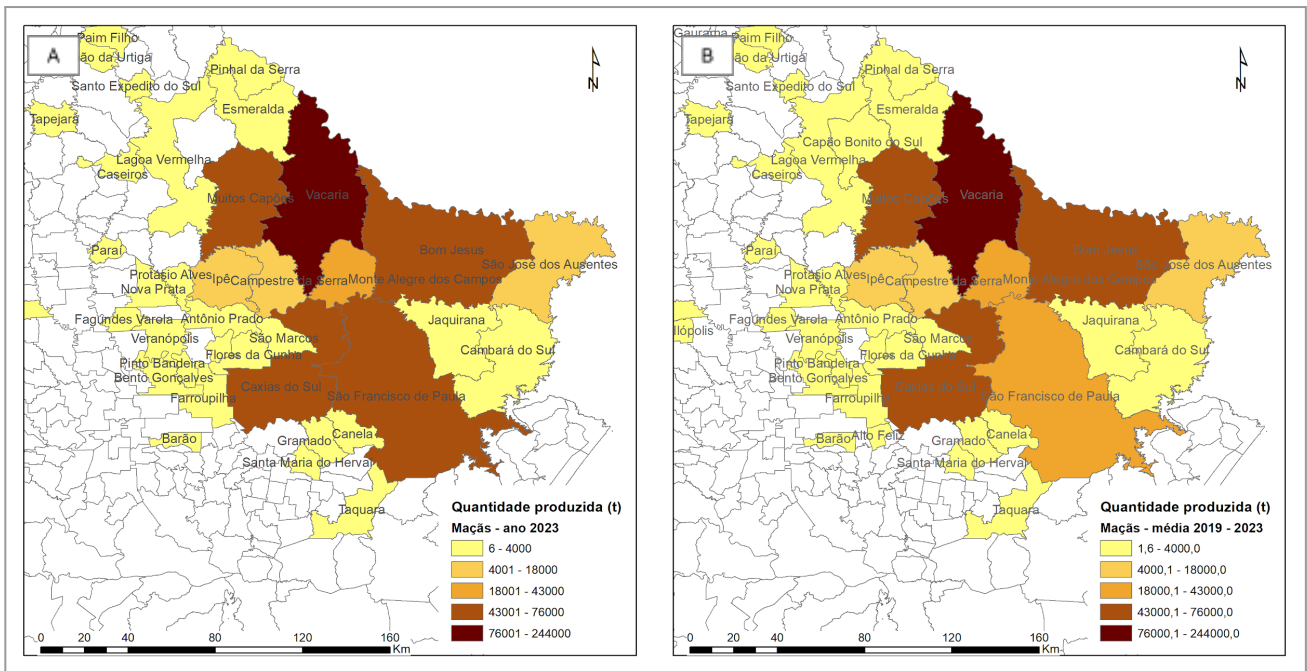


Figura 2 - Quantidade (t) de maçãs produzidas, por município, no estado do RS. A: Em 2023; B: Média entre 2019-2023




Figura 3 - Dez principais municípios produtores de maçã, no Estado do RS



Além de sua relevância produtiva, Vacaria caracteriza-se pela adoção de tecnologias voltadas à mitigação de riscos climáticos, com ênfase nas estruturas de proteção contra granizo, como as telas fixadas em capela. A região é frequentemente atingida por eventos de precipitação granílica entre os meses de julho e outubro, o que justifica a ampla implementação dessas estruturas, tanto em pomares empresariais quanto familiares (Lazzarotto e Fioravanço, 2020).

2.2- Dados e Metodologia

Foram utilizadas imagens do sensor Sentinel-2 MSI, nível 2A (reflectância de superfície – SR). As bandas espectrais empregadas foram: B2 (Azul – 490 nm); B3 (Verde – 560 nm); B4 (Vermelho – 665 nm) e B8 (Infravermelho próximo – 842 nm), todas com resolução espacial de 10 metros. Foi aplicada uma máscara de cobertura de nuvens, seguida da seleção das melhores cenas para compor um mosaico livre de interferência atmosférica, cobrindo todo o município. Adicionalmente, foram calculados índices espectrais derivados, como o NDVI (*Normalized Difference Vegetation Index*), com o objetivo de melhorar a separação entre classes espectralmente semelhantes.

A abordagem metodológica utilizou dois tratamentos classificatórios distintos: orientação a objetos (OBIA) e pixel a pixel, ambos aplicando o algoritmo de aprendizado supervisionado *Random Forest* (Breiman, 2001). O processo foi inteiramente desenvolvido na plataforma *Google Earth Engine* (GEE), que permite o processamento de imagens orbitais em larga escala, com alto desempenho computacional e integração de dados espectrais e temporais.

Na etapa de segmentação baseada em objetos, foi empregado o algoritmo *K-means*, método não supervisionado que agrupa pixels em k clusters com base na similaridade espectral e geométrica. O objetivo da segmentação foi otimizar a identificação de padrões espaciais característicos das estruturas protegidas. O critério de agrupamento busca minimizar a soma dos erros quadráticos intra-cluster:

$$J = \sum_{i=1}^k \sum_{x \in C_i} \|x - \mu\|^2 \quad (1)$$

Em que C_i é o conjunto de pixels pertencentes ao cluster i , e μ o centróide correspondente.

Na sequência, empregou-se o algoritmo *Random Forest*, amplamente utilizado em estudos de uso e cobertura da terra pela sua robustez frente a dados de alta dimensionalidade. O algoritmo constrói múltiplas Árvores de Decisão com base em subconjuntos aleatórios do conjunto de treinamento e, para cada nó, realiza divisões que maximizam o ganho de informação, medido pelo índice de Gini:



$$G(t) = 1 - \sum_{j=1}^c p(j|t)^2 \quad (2)$$

O ganho resultante de uma divisão é dado por:

$$\Delta G = G(t) - p_L G(t_L) - p_R G(t_R) \quad (3)$$

Em que: p_L e p_R são as proporções de amostras direcionadas para os nós esquerdo e direito, respectivamente.

Para a etapa de classificação supervisionada, foram consideradas quatro classes temáticas na área de estudo: cultivos protegidos por tela antigranizo, cultivos desprotegidos, mata nativa densa e vegetação secundária. Embora o foco principal da análise fossem as áreas protegidas por telas, a inclusão das demais classes foi essencial para melhorar a acurácia da classificação e evitar confusões espectrais com elementos do entorno. No total, foram utilizados 800 pontos amostrais, dos quais 70% foram selecionados aleatoriamente para o treinamento do algoritmo *Random Forest* e 30% para a validação dos resultados.

A necessidade de se incluir a classe “vegetação secundária” surgiu a partir de testes preliminares, que demonstraram recorrência de erros de classificação em áreas com vegetação jovem ou raleada, cujas características espectrais, especialmente a coloração clara em determinadas composições, levavam o modelo a confundi-las com telas antigranizo, geralmente brancas e expostas. A presença dessa classe adicional permitiu maior robustez ao modelo, diferenciando padrões que, à primeira vista, apresentavam comportamento espectral semelhante.

A imagem classificada foi submetida a um pós-processamento de redução de ruído, com base em análise de vizinhança, visando à correção de inconsistências pontuais. Neste procedimento, pixels isolados, cujos rótulos divergiam da classe predominante em seu entorno, foram reclassificados de forma a suavizar a segmentação e reduzir a presença de artefatos espúrios na classificação final.

Após essa etapa, os resultados obtidos pelos dois modelos — classificação pixel a pixel e orientada a objetos (OBIA) — foram comparados tanto em relação à área total de telas identificadas quanto à precisão na detecção da classe-alvo, possibilitando uma avaliação cruzada do desempenho das abordagens testadas.

Como etapa complementar e referência para validação, procedeu-se com a vetorização visual das áreas protegidas no município, a partir da inspeção manual das cenas. Essa vetorização foi confrontada com informações empíricas obtidas por meio de dados de campo coletados pela equipe técnica da Embrapa Uva e Vinho, que sanaram dúvidas a partir de registros



georreferenciados de pomares. Esses dados forneceram subsídios tanto para a rotulagem das amostras de treinamento quanto para a validação da classificação visual, possibilitando a comparação entre a área real ocupada por telas no município e a extensão estimada pelos modelos testados neste estudo.

3- RESULTADOS E DISCUSSÃO

Para avaliar o desempenho dos dois modelos de classificação — pixel a pixel e orientado a objetos (OBIA) — foram construídas as respectivas matrizes de confusão com base nos dados de validação, permitindo o cálculo dos principais índices estatísticos de acurácia. Os indicadores considerados incluíram a acurácia global, o índice Kappa e a precisão da classe-alvo, esta última referindo-se especificamente à capacidade do modelo em identificar corretamente os cultivos protegidos por tela, que constituem o foco da detecção.

A classificação pixel a pixel apresentou os melhores resultados entre os dois métodos testados, com acurácia global de 0.76, índice Kappa de 0.68 e precisão da classe de 0.95, conforme demonstrado na Tabela 1. Esses valores indicam não apenas uma boa correspondência geral entre a classificação e os dados de referência, mas também um maior desempenho específico na identificação das áreas protegidas por tela. O índice Kappa, que corrige o efeito do acaso na concordância, reforça a confiabilidade do modelo, situando-se acima do limiar de 0.60, interpretado como indicativo de uma concordância substancial, conforme a escala de Landis e Koch (1977).

O modelo baseado em orientação a objetos (OBIA) também apresentou resultados satisfatórios, mas ligeiramente inferiores aos obtidos pela abordagem pixel a pixel. A acurácia global atingiu 0.74, o índice Kappa foi de 0.65 e a precisão da classe chegou a 0.93. O desempenho superior da classificação pixel a pixel pode estar associado à maior sensibilidade desse modelo a variações espectrais sutis, o que favorece a detecção de coberturas específicas - como as telas antigranizo - especialmente em um contexto espacial heterogêneo como o da área estudada. Esses resultados estão em consonância com estudos anteriores que também empregaram o algoritmo *Random Forest* na detecção de estruturas agrícolas (Chen et al., 2023; Blanco et al., 2018).



Tabela 1: Valores de acurácia da classificação *Random Forest* - pixel a pixel e orientada a objeto (OBIA)

Modelo	Índice Kappa	Acurácia Global	Precisão da Classe
Pixel a pixel	0,68	0,76	0,95
OBIA	0,65	0,74	0,93

A abordagem pixel a pixel apresentou menores erros de omissão e comissão. Por outro lado, a OBIA demonstrou tendência à superestimação, especialmente em regiões onde a reflectância da vegetação secundária se aproxima daquela registrada em coberturas plásticas, conforme apontado em trabalhos de Zhang et al., 2022. Essa limitação reforça a importância da validação em campo, realizada com o suporte da Embrapa Uva e Vinho, para ajustar os parâmetros de classificação e minimizar falsos positivos (Figuras 4 e 5).




Figura 4 - A: Vetorização visual; B: Classificador *Random Forest* - pixel a pixel

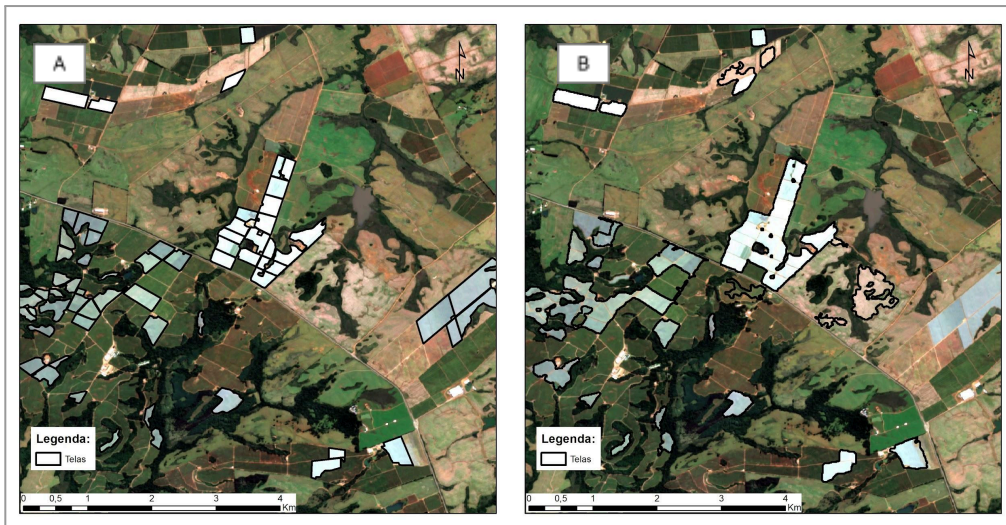


Figura 5 - A: Vetorização visual; B: Classificador *Random Forest* - OBIA

As estimativas de área coberta por telas antigranizo variaram conforme a metodologia empregada. A vetorização visual, considerada neste estudo como referência, identificou 15,8 Km² de área protegida. A classificação pixel a pixel estimou 18,7 Km², enquanto a abordagem baseada em objetos (OBIA) resultou em 19,9 Km². Ambas as classificações superestimaram a área real, com o erro absoluto de 2,9 Km² na abordagem pixel a pixel e de 4,1 Km² na OBIA, o que corresponde a desvios percentuais de 18,3% e 26,0%, respectivamente. Os respectivos valores encontram-se na Tabela 2.

Tabela 2- Valores da área (Km²) de cultivos cobertos por tela, utilizando as diferentes abordagens

Abordagem	Área estimada (km ²)	Erro absoluto	Erro percentual (%)
Pixel a pixel	18,7	2,9	18,3
OBIA	19,9	4,1	26,0
Vetorização visual	15,8	—	—

A discrepância observada nos resultados da abordagem OBIA pode ser explicada, em parte, pelas limitações inerentes ao algoritmo de segmentação K-means, que nem sempre é capaz de delinear com precisão os contornos das áreas de interesse em ambientes agrícolas com alta heterogeneidade espacial. Em cenários como o de Vacaria, onde cultivos protegidos por telas convivem lado a lado com diferentes tipos de vegetação, o algoritmo tende a agrupar erroneamente pixels com padrões espectrais semelhantes, o que favorece a inclusão indevida de áreas adjacentes, especialmente quando há transições sutis entre coberturas plásticas e vegetação secundária.



Adicionalmente, a resolução espacial das imagens Sentinel-2 (10 metros) representa um fator limitante adicional, dificultando a separação entre alvos espectralmente semelhantes, como as telas antigranizo e vegetação com dossel ralo ou clareiras expostas. Esse cenário favorece a ocorrência de superestimação da classe-alvo nas classificações orientadas a objetos, como evidenciado neste estudo.

Por outro lado, a abordagem pixel a pixel apresentou melhor desempenho, resultado que pode ser atribuído à sua maior sensibilidade às assinaturas espectrais específicas das telas antigranizo, sobretudo no canal do infravermelho próximo (NIR), em que os materiais plásticos tendem a apresentar elevada reflectância (Zhang et al., 2022). Essa característica favorece a distinção entre as coberturas protegidas e demais elementos do cenário agrícola, conferindo maior precisão à classificação.

Em consonância com Schimalski et al. (2022), os resultados obtidos reforçam que os dados orbitais do Sentinel-2 constituem uma fonte confiável e tecnicamente viável para o monitoramento da fruticultura protegida, oferecendo suporte à quantificação espacial de pomares e ao planejamento da produção agrícola em regiões expostas a riscos climáticos severos.

4. CONCLUSÃO

Os resultados obtidos neste estudo demonstram o potencial do uso combinado de imagens Sentinel-2 e algoritmos de aprendizado de máquina, especificamente o *Random Forest*, para o mapeamento de estruturas agrícolas, como as telas antigranizo. A comparação entre os dois modelos testados — classificação pixel a pixel e orientada a objetos (OBIA) — evidenciou a superioridade da abordagem pixel a pixel, tanto em termos de acurácia estatística quanto de proximidade da estimativa de área em relação ao valor de referência obtido por vetorização visual. O aprimoramento futuro da metodologia pode envolver o uso de sensores com maior resolução espacial, a integração de séries temporais para discriminar sazonalmente os alvos e o refinamento de técnicas de segmentação espacial.

5. AGRADECIMENTOS

Agradecemos ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro, por meio do Programa Institucional de Bolsas de Iniciação Científica (PIBIC). Agradecemos também à Embrapa Uva e Vinho pela validação de campo.



6. REFERÊNCIAS

- AMARANTE, L. M.; LEITE, G. B.; STAMPAR, S.; WIDMER, R. Yield and fruit quality of 'Gala' and 'Fuji' apple trees protected by white anti-hail net. *Scientia Horticulturae*, v. 129, p. 123–130, 2007. DOI: 10.1016/j.scienta.2011.03.010.
- BLANCO, I.; COLUCCI, A.; DELLA TORRE, C. Agricultural plastic waste mapping using GIS: a case study in Italy. *Resources, Conservation & Recycling*, v. 137, p. 229–242, 2018. DOI: 10.1016/j.resconrec.2018.06.008.
- BREIMAN, L. Random forests. *Machine Learning*, v. 45, n. 1, p. 5–32, 2001. DOI: 10.1023/A:1010933404324.
- CHEN, D.; MA, A.; ZHENG, Z.; ZHONG, Y. Large-scale agricultural greenhouse extraction for remote sensing imagery based on layout attention network. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 200, p. 73–88, 2023. DOI: 10.1016/j.isprsjprs.2023.04.020.
- DIMITROVSKI, I.; KITANOVSKI, I.; KOCEV, D.; SIMIDJEVSKI, N. A benchmark dataset and evaluation methodology for greenhouse detection. *Remote Sensing*, v. 13, n. 20, p. 2428, 2021.
- HOFMANN, T.; ADLER, P.; SCHMIDT, T. C. Plastics can be used more sustainably in agriculture. *Communications Earth & Environment*, v. 4, n. 332, 2023. DOI: 10.1038/s43247-023-00982-4.
- IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Produção agrícola municipal: quantidade produzida e valor da produção da lavoura permanente por tipo de produto – maçã [base de dados]. Rio de Janeiro: IBGE, 2023. Disponível em: <https://sidra.ibge.gov.br/tabela/1612>. Acesso em: 30 ago. 2024.
- LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. *Biometrics*, v. 33, n. 1, p. 159–174, 1977.
- LAZZAROTTO, J. J.; FIORAVANÇO, J. C. Impactos do granizo sobre o desempenho econômico e financeiro da produção de maçã em pomares protegidos com tela ou com seguro agrícola. Bento Gonçalves: Embrapa Uva e Vinho, 2020. 27 p. (Documentos Embrapa Uva e Vinho, n. 119). ISSN 1808-4648.
- LI, X.; ZHANG, Y.; WANG, J.; LI, M.; ZHAO, X. Effects of different coverage years of hail-proof nets on environment, leaf traits and fruit quality in apple orchards. *Plants*, v. 11, n. 2, p. 198, 2024. <https://doi.org/10.3390/horticulturae11020198>.
- LIU, Z.; GUO, X.; WANG, W. Effects of microplastics on water infiltration in agricultural soil. *Agricultural Water Management*, v. 271, p. 107818, 2022. DOI: 10.1016/j.agwat.2022.107818.
- SCHIMALSKI, M. B.; RUFATO, L.; JASTRUMBEEK, J. M.; LIESENBERG, V. Mapping Apple Orchards in the municipality of São Joaquim (Santa Catarina, Brazil) using Sentinel-2 data. *Revista Brasileira de Fruticultura*, Jaboticabal, v. 44, n. 1, p. 1–12, 2022. DOI: 10.1590/0100-29452022842.
- ZHANG, P.; DU, P.; GUO, S.; ZHANG, W.; TANG, P.; CHEN, J.; ZHENG, H. A novel index for robust and large-scale mapping of plastic greenhouses from Sentinel-2 images. *Remote Sensing of Environment*, v. 276, p. 113042, 2022. DOI: 10.1016/j.rse.2022.113042.