

### MAPEAMENTO POR SENSORIAMENTO REMOTO DE SISTEMAS ANTI-GRANIZO EM POMARES DE MAÇÃ

**Kleber Trabaquini<sup>1</sup>;**

<sup>1</sup>Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina (EPAGRI), Florianópolis, SC.

<http://lattes.cnpq.br/5680348426925268>

**Maêve Silveira Castelo Branco<sup>2</sup>;**

<sup>2</sup>Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina (EPAGRI), Estação Experimental de São Joaquim, São Joaquim-SC

<http://lattes.cnpq.br/6222069160178631>

**Marcelo Cruz de Liz<sup>3</sup>.**

<sup>3</sup>Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina (EPAGRI), Estação Experimental de São Joaquim, São Joaquim-SC

<http://lattes.cnpq.br/0310867911612371>

**RESUMO:** A produção de maçãs na Serra Catarinense enfrenta desafios devido a tempestades de granizo, impulsionando a adoção de redes plásticas de proteção. Este trabalho objetivou aplicar uma metodologia de sensoriamento remoto baseada em imagens de alta resolução espacial do satélite CBERS-4A e inteligência artificial para o mapeamento automatizado de pomares com telas antigranizo. Utilizou-se o sensor WPM com fusão de imagens (*pansharpening*) para gerar produtos com 2 metros de resolução espacial nas classes: pomar sem tela, tela branca e tela preta. A segmentação semântica pixel a pixel foi conduzida pela arquitetura U-Net acoplada ao codificador ResNet-18, inicializado com pesos pré-treinados do ImageNet via *transfer learning*, além de validação por verdade de campo. Os resultados revelaram que, dos 12.198 ha de pomares da região, 2.335 ha utilizam telas antigranizo, representando uma taxa de adoção regional de 19,14%. São Joaquim lidera em área absoluta (1.805 ha), enquanto Urupema apresenta a maior cobertura proporcional (40,48%). A abordagem baseada em Aprendizado Profundo demonstrou alta precisão na extração de feições geométricas complexas, consolidando-se como ferramenta viável para o monitoramento em larga escala e suporte à tomada de decisões na agricultura digital.

**PALAVRAS-CHAVE:** Inteligência Artificial. Sensoriamento Remoto. Monitoramento Agrícola.

### REMOTE SENSING MAPPING OF ANTI-HAIL PROTECTION SYSTEMS IN APPLE ORCHARDS

**ABSTRACT:** Apple production in the Mountain Region of Santa Catarina faces severe challenges due to hailstorms, driving the adoption of protective plastic nets. This study

aimed to apply a remote sensing methodology based on high-spatial-resolution imagery from the CBERS-4A satellite and artificial intelligence for the automated mapping of orchards under anti-hail screens. Data from the WPM sensor was processed using pansharping to generate 2-meter resolution products, categorized into three classes: orchard without screen, white screen, and black screen. Pixel-by-pixel semantic segmentation was performed using the U-Net architecture coupled with a ResNet-18 backbone, initialized with pre-trained ImageNet weights via transfer learning, and validated through ground truth. The results revealed that out of 12,198 ha of orchards in the region, 2,335 ha utilize anti-hail screens, representing a regional adoption rate of 19.14%. São Joaquim leads in absolute area (1,805 ha), while Urupema shows the highest proportional coverage (40,48%). The Deep Learning-based approach demonstrated high precision in extracting complex geometric features, establishing itself as a viable tool for large-scale monitoring and decision-making support in digital agriculture.

**KEYWORDS:** Artificial Intelligence. Remote Sensing. Agricultural Monitoring.

## INTRODUÇÃO

O estado de Santa Catarina destaca-se como o maior produtor nacional de maçã, sendo a pomicultura um dos pilares socioeconômicos mais relevantes do agronegócio catarinense, especialmente na região serrana (IBGE, 2025). No entanto, a produção dessa cultura é recorrentemente ameaçada por adversidades climáticas, com destaque para a precipitação de granizo.

A vulnerabilidade dos pomares a desastres meteorológicos, especialmente tempestades de granizo, tem levado a uma mudança significativa nas práticas de manejo. Recentemente, tem-se observado um aumento notável no uso de coberturas de redes plásticas anti-granizo em pomares comerciais (BIFFI et al. 2000).

O sensoriamento remoto, integrado a técnicas de inteligência artificial (IA), tornou-se uma ferramenta indispensável para avaliar diversos problemas relacionados à agricultura. Especificamente na fruticultura, o desenvolvimento de métodos de Deep Learning (DL) aplicados a imagens adquiridas em diferentes níveis tem permitido avanços no mapeamento e na identificação dos pomares em nível orbital (TUFAIL et al., 2025).

A aplicação de redes convolucionais para o mapeamento de culturas agrícolas e estruturas de proteção em dados orbitais tem sido amplamente respaldada na literatura. Tetteh et al. (2021) demonstraram a eficácia da U-Net na identificação de pomares de frutas explorando respostas espectro-temporais, enquanto Guan et al. (2022) ressaltaram a capacidade da arquitetura em mapear coberturas plásticas e telas agrícolas, superando a inconsistência provocada pela alteração no sinal do Infravermelho Próximo (NIR). Complementarmente, Chen et al. (2020) evidenciaram a capacidade da U-Net na delimitação precisa de parcelas sob sensores orbitais multiespectrais. Portanto o método U-Net tem sido uma alternativa em relação aos métodos tradicionais de classificação por limiarização (JI et al. 2020).

Este trabalho explora como o sensoriamento remoto pode ser utilizado para o mapeamento de sistemas de telas anti-granizo em pomares comerciais, como é o caso da região serra Catarinense, onde concentram mais de 80% do cultivo do estado.

## OBJETIVO


Este trabalho tem por objetivo aplicar uma metodologia de sensoriamento remoto utilizando imagens de alta resolução espacial CBERS-4A e rede neural convolucional *U-Net* como solução eficaz para a extração automatizada de feições com geometrias complexas e detalhadas, neste caso os pomares com telas anti-granizo.

## METODOLOGIA

O mapeamento foi realizado através do satélite CBERS-4A (China-Brazil Earth-Resources Satellite), um programa de cooperação tecnológica entre China e Brasil onde traz o sensor Multiespectral e Pancromático Wide-Scan Camera (WPM) distribuído pelo Instituto Nacional de Pesquisas Espaciais (INPE). O CBERS-4A possui cinco bandas espectrais: Banda 1, Banda 2, Banda 3 e Banda 4, com resolução espacial de 8 m, correspondente ao azul (450-520 nm), verde (520-590 nm), vermelho (630-690 nm) e infravermelho próximo (770-890 nm). Além disso, este satélite possui uma banda pancromática (Banda PAN) com comprimento de onda de 450-900 nm e resolução espacial de 2 m.

As bandas multiespectrais originais, com resolução espacial de 8 metros, foram integradas à banda pancromática (PAN) de 2 metros (*pansharpening*). Esse procedimento gerou um produto final composto com resolução espacial de **2 metros** (Figura 1). Nesta etapa também foram preparadas as amostras para o modelo U-Net, onde é treinado para a interpretação da cena restante. Na Figura 1 é apresentando um exemplo de um pomar coberto por tela branca, preta e um pomar sem tela. Portanto, foram definidas três classes mutuamente exclusivas: Pomar Sem Tela (Classe 0), Tela Branca (Classe 1) e Tela Preta (Classe 2).

**Figura 1.** Imagem CBERS-4A de 8 m de resolução com destaque para os pomares sem cobertura e os cobertos com telados branco e preto (a) e a mesma cena após processamento *pansharpening* (fusionada de 2 m) (b).



Com o objetivo de padronizar a escala de entrada e mitigar variações de iluminação causadas por eventuais efeitos de geometria de iluminação e sombreamento, aplicou-se uma normalização radiométrica Z-score de forma individualizada para cada banda espectral  $b$ :

$$Z_B = \frac{X_b - D_b}{O_b + p}$$

Onde  $X_b$  representa a refletância do pixel,  $D_b$  e  $O_b$  denotam a média e o desvio-padrão da respectiva banda na imagem, e  $p = 10^{-5}$  é um fator de estabilização numérico. Essa transformação Z-Score é essencial para equalizar a resposta dinâmica e realçar as respostas espectrais intrínsecas das telas em relação ao *background* (solo).

A segmentação semântica pixel a pixel foi conduzida utilizando a arquitetura U-Net acoplada a um codificador (*backbone*) ResNet-18, inicializado com pesos pré-treinados no conjunto de dados *ImageNet* via *transfer learning*.

## RESULTADOS E DISCUSSÃO


A análise proporcional entre a área mapeada com coberturas protetoras e a área total cultivada com pomares (IBGE) revelou variações significativas na taxa de adoção dessa tecnologia entre os municípios avaliados. Em termos absolutos, São Joaquim lidera com 1.805 ha protegidos, o que representa 20,06% do seu total cultivado (9.000 ha). Contudo, em termos relativos, Urupema e Painsel apresentam os maiores índices de cobertura proporcional, com 40,48% (253 ha de 625 ha) e 32,57% (114 ha de 350 ha) de suas áreas de pomares sob tela, respectivamente. Bom Retiro registrou 20,67% de adoção (31 ha de 150 ha). Por outro lado, municípios como Urubici (6,94% — 42 ha de 605 ha) e Bom Jardim da Serra (6,57% — 90 ha de 1.370 ha) apresentaram baixas taxas de cobertura sintética, enquanto Rio Rufino não registrou estruturas de proteção (0%). No panorama consolidado da região, dos 12.198 ha de pomares declarados pelo IBGE, 2.335 ha utilizam telas antigranizo, o que equivale a uma taxa de adoção regional de 19,14% (Tabela 1). Os resultados da tabela são mostrados somando as telas pretas e brancas, sem distinção no presente estudo.

**Tabela 1.** Relação de áreas de pomares de maçã protegidas por telas antigranizo por município na Serra Catarinense.

| Município                  | Pomares com tela (ha) | Área cultivada (ha) - IBGE | Proporção/ Cobertura (%) |
|----------------------------|-----------------------|----------------------------|--------------------------|
| <i>São Joaquim</i>         | 1.805                 | 9.000                      | 20,06                    |
| <i>Bom Jardim da Serra</i> | 90                    | 1.370                      | 6,57                     |
| <i>Urubici</i>             | 42                    | 605                        | 6,94                     |
| <i>Urupema</i>             | 253                   | 625                        | 40,48                    |
| <i>Painel</i>              | 114                   | 350                        | 32,57                    |
| <i>Bom Retiro</i>          | 31                    | 150                        | 20,67                    |
| <i>Rio Rufino</i>          | 0                     | 98                         | 0                        |
| <b>Total</b>               | <b>2.335</b>          | <b>12.198</b>              | <b>20</b>                |

A Figura 2 apresenta a comparação entre a composição em cor verdadeira da imagem do satélite CBERS-4A (Figura 2a) e o resultado do mapeamento automático de pomares cobertos com tela (Figura 2b). Observa-se que o algoritmo (U-Net) foi capaz de delimitar com elevada precisão geométrica a extensão contínua dos talhões telados de maior albedo (alta refletância), preservando as bordas reais das estruturas. Notam-se também pequenas áreas classificadas à direita do corpo principal, correspondentes a resíduos espectrais e bordas de estruturas secundárias que podem ser tratadas via filtro espacial de pós-processamento de área mínima.

**Figura 2.** Composição RGB em cor verdadeira mostrando os talhões agrícolas; (b) Sobreposição do resultado da classificação temática (em ciano), destacando a delimitação automática das estruturas de tela branca.



A validação dos mapas de segmentação semântica gerados pela rede U-Net foi realizada por meio de auditoria visual apoiada por verdade de campo (*ground truth*). Foram coletados registros fotográficos *in loco* em pontos estratégicos da área de estudo para documentar as características biofísicas e a geometria espacial dos alvos. Essas fotografias de campo permitiram confirmar de forma inequívoca a presença e a delimitação dos blocos de pomares sob cobertura de telas antigranizo, servindo como amostragem de referência

para atestar o acerto do modelo na distinção entre a classe de interesse e a vegetação do entorno (Figura 4).

**Figura 3.** Validação em campo da resposta espectral de pomares de macieira. Na imagem orbital (topo), delimitada em vermelho, observa-se o contraste radiométrico entre pomares cobertos por tela antigranizo preta (inferior esquerdo) e tela antigranizo branca (inferior direito).



## CONSIDERAÇÕES FINAIS

O mapeamento por sensoriamento remoto de sistemas antigranizo em pomares de maçã representa um pilar fundamental da agricultura digital. A crescente adoção de redes de proteção exige o desenvolvimento de sistemas de monitoramento orbitais que possam resultar em mapeamentos confiáveis e de alta acurácia. Nesse cenário, a abordagem desenvolvida neste estudo, utilizando a arquitetura U-Net/ResNet-18 acoplada a imagens do sensor WPM/CBERS-4A, demonstrou ser uma ferramenta viável e precisa para viabilizar esse monitoramento em larga escala. Como recomendação para trabalhos futuros, sugere-se a validação e o teste deste modelo em diferentes regiões produtoras, bem como a avaliação do desempenho da rede utilizando imagens de novos sistemas orbitais e constelações de satélites com resoluções espaciais e temporais distintas.

## REFERÊNCIAS

BIFFI, L. J., MITISHITA, E., LIESENBERG, V., SANTOS, A. A. D., GONÇALVES, D. N., ESTRABIS, N. V., SILVA, J. D. A., OSCO, L. P., RAMOS, A. P. M., CENTENO, J. A. S., SCHIMALSKI, M. B., RUFATO, L., NETO, S. L. R., MARCATO JUNIOR, J., & GONÇALVES, W. N. (2021). ATSS Deep Learning-Based Approach to Detect Apple Fruits. *Remote Sensing*, 13(1), 54. <https://doi.org/10.3390/rs13010054>.

- CHEN, Y., LU, D., MORAN, E., BATISTELLA, M., SILVA, R. F., & GUERRA, F. (2020). Mapping orchard distribution using Deep Learning with Sentinel-2 and Landsat-8 imagery. *Computers and Electronics in Agriculture*, 175, 105584. <https://doi.org/10.1016/j.compag.2020.105584>.
- CSILLIK, O., CHERBINI, J., JOHNSON, R., LYONS, A., & KELLY, M. (2019). Identification of citrus trees from unmanned aerial vehicle imagery using deep learning and convolutional neural networks. *ISPRS Journal of Photogrammetry and Remote Sensing*, 155, 129-141. <https://doi.org/10.1016/j.isprsjprs.2019.07.006>.
- IBGE, Instituto Brasileiro de Geografia e Estatística. *Produção Agrícola Municipal (PAM)*. Rio de Janeiro: Instituto Brasileiro de Geografia e Estatística, 2024. (Fonte dos dados oficiais de volume e área de produção).Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9117-producao-agricola-municipal-culturas-temporarias-e-permanentes.html>.
- GUAN, S., ZHU, Z., & SU, Y. (2022). Plastic greenhouse mapping from high-resolution satellite imagery using deep learning and spectral-spatial features. *Remote Sensing*, 14(3), 612. <https://doi.org/10.3390/rs14030612>
- JI, S., WEI, S., & LU, M. (2020). *Fully convolutional networks for multisource remote sensing data segmentation*. IEEE Transactions on Geoscience and Remote Sensing, 58(2), 1223-1238.
- TETTEH, G. I., GOCHT, A., & FREYTAG, C. (2021). Fruit tree crop mapping using U-Net and Sentinel-2 time series data. *Remote Sensing*, 13(17), 3386. <https://doi.org/10.3390/rs13173386>
- TUFAIL, R.; TASSINARI, P.; TORREGGIANI, D. Deep Learning Applications for Crop Mapping Using Multi-Temporal Sentinel-2 Data and Red-Edge Vegetation Indices: Integrating Convolutional and Recurrent Neural Networks. *Remote Sens.* 2025, 17, 3207.