

## APRENDIZADO DE MÁQUINA APLICADO À DETECÇÃO DE ERVAS DANINHAS

**ERICK HERCULANO PEREIRA JUNIOR<sup>1</sup>, AMÉLIA LAISY DO NASCIMENTO<sup>2</sup>,  
EMANOEL DI TARSO DOS SANTOS SOUSA<sup>2</sup>, MARCO ANTONIO ZANELLA<sup>2</sup>,  
VANESSA ADELINO DOS SANTOS<sup>3</sup>, ARIK MENDES ESTIMA<sup>3</sup>**

<sup>1</sup> Discente de graduação, Universidade Federal Rural de Pernambuco, erick.herculano.pereira@gmail.com

<sup>2</sup> Doutor(a), Docente, Universidade Federal Rural de Pernambuco

<sup>3</sup> Discente de graduação, Universidade Federal Rural de Pernambuco

Apresentado no  
LIII Congresso Brasileiro de Engenharia Agrícola - CONBEA 2024  
6 a 8 de agosto de 2024 – Natal – RN, Brasil

**RESUMO:** Pragas, doenças e ervas daninhas são responsáveis por significativas perdas de rendimento nas culturas agrícolas. O uso de herbicidas é o principal método para controle das mesmas. Apesar da importância dos herbicidas, a sociedade tem exigido práticas de manejo ecológico com diminuição do volume de agrotóxicos utilizados na agricultura. Uma das formas de reduzir a quantidade de agrotóxico é por meio da aplicação localizada, em que o tratamento é realizado apenas em locais cuja infestação está acima do nível do limiar econômico. Visando a redução do uso de defensivos agrícolas e minimizar impactos ambientais, foram utilizados métodos de aprendizado de máquina para detecção de ervas daninhas em áreas agrícolas. Os métodos de classificação árvore de decisão, rede neural artificial, floresta aleatória e máquina de vetor de suporte foram aplicados em imagens de uma área cultivada com cana-de-açúcar localizada no norte do Brasil. Os resultados demonstraram que todos os métodos apresentaram alta exatidão global (entre 81,9% e 83,8%), porém houve dificuldade na distinção entre erva daninha e cana-de-açúcar. Conclui-se que os métodos avaliados apresentam potencial para auxiliar no manejo localizado de culturas, mas ainda demandam refinamentos para melhor distinguir as classes de interesse.

**PALAVRAS-CHAVE:** Agrotóxicos, classificação, visão computacional

### MACHINE LEARNING APPLIED TO WEED DETECTION

**ABSTRACT:** Pests, diseases and weeds are responsible for significant yield losses in agricultural crops. The use of herbicides is the main method for controlling them. Despite the importance of herbicides, society has demanded ecological management practices with a reduction in the volume of pesticides used in agriculture. One of the ways to reduce the amount of pesticides is through localized application in which the treatment is carried out only in places where infestation is above the economic threshold level. Aiming to reduce the use of agricultural pesticides and minimize environmental impacts, machine learning methods were used to detect weeds in agricultural areas. Initially, the use of satellite images was planned, however, drone images were chosen due to the low resolution of the former. The classification methods Decision Tree, Artificial Neural Network, Random Forest and Support Vector Machine were applied to images of an area cultivated with sugar cane. The results demonstrated high overall accuracy (between 81.9% and 83.8%), but with difficulty in distinguishing between weed and sugarcane. It is concluded that the methods evaluated have

the potential to assist in localized crop management, but still require refinements to better distinguish the classes of interest.

**KEYWORDS:** Classification, computer vision, , pesticides

**INTRODUÇÃO:** Pragas, doenças e ervas daninhas representam uma ameaça significativa para a produção agrícola, contribuindo para perdas substanciais de rendimento (SOLTANI et al., 2018). O uso predominante de herbicidas, embora eficaz, enfrenta crescente escrutínio da sociedade devido aos seus potenciais impactos ambientais e à demanda por práticas agrícolas mais sustentáveis (GIANESSI, 2013). Nesse contexto, a aplicação localizada de agrotóxicos, baseada nos princípios da agricultura de precisão, emerge como uma estratégia promissora para reduzir o consumo de defensivos agrícolas, minimizando os custos e os impactos ambientais associados (JURADO-EXPÓSITO et al., 2003). O sensoriamento remoto, especialmente por meio de veículos aéreos não tripulados, oferece uma abordagem eficiente para o monitoramento de culturas, possibilitando a obtenção de dados com alta resolução espacial e temporal (BAH; HAFIANE; CANALS, 2018). O processamento de imagens e o emprego de técnicas de aprendizado de máquina têm sido cada vez mais explorados para a detecção automatizada de pragas, doenças e ervas daninhas em áreas agrícolas, visando aprimorar a eficiência dos métodos de manejo e reduzir as perdas de produção (STOREY; MENG; LI, 2022). No entanto, apesar dos avanços alcançados, a detecção automática ainda enfrenta desafios significativos, especialmente em relação à precisão e à escalabilidade (BAH; HAFIANE; CANALS, 2018). Além disso, a avaliação da eficácia da aplicação de defensivos agrícolas permanece como uma questão não resolvida, pois a mensuração precisa do tamanho das áreas afetadas por pragas, doenças e ervas daninhas é fundamental para garantir a adequada tomada de decisão e o uso eficiente dos recursos (JURADO-EXPÓSITO et al., 2003). Em vista disso, esta pesquisa teve como objetivo investigar e comparar diferentes métodos de aprendizado de máquina e visão computacional para a detecção de ervas daninhas em áreas agrícolas cultivadas.

**MATERIAL E MÉTODOS:** Para o estudo do presente trabalho, foi utilizado o banco de dados construído por Monteiro e Wangenheim (2019), que contém imagens de um campo cultivado com cana-de-açúcar no norte do Brasil. As imagens do banco de dados público disponibilizado por Monteiro e Wangenheim (2019) foram capturadas pela câmera digital RGB Canon G9X a bordo de um veículo aéreo não tripulado (VANT) de asa fixa. O VANT sobrevoou o campo cultivado com cana-de-açúcar a uma altura de 125 a 200 metros. Os resultados dessa captura foram imagens com resolução espacial de aproximadamente 5cm/pixel. Na sequência, as imagens capturadas foram agrupadas em um orthomosaico (Figura 1a). O campo cultivado com cana-de-açúcar contém a presença de ervas daninhas além de uma grande parcela de solo exposto (Figura 1b). Um biólogo especialista classificou, manualmente pixel-a-pixel, a imagem original nas classes: solo exposto, erva daninha e cana-de-açúcar. Dessa forma, foi produzida uma imagem da área de estudo do tipo verdade fundamental (Figura 1c). Para a classificação da área de maneira automática por computador, foram usados 4 diferentes métodos de classificação: árvore de decisão (rpart), floresta aleatória (rf), rede neural artificial (nnet) e máquina de vetor de suporte (svm). No programa de computador Qgis, foram selecionados 320 pontos sobre a imagem orthomosaico. Os pontos foram escolhidos aleatoriamente em pixels correspondentes a solo exposto, ervas daninhas e plantação de cana-de-açúcar. Na tabela de atributos foi adicionada a informação de qual classe (solo exposto, erva daninha, cana-de-açúcar) o pixel correspondia. Esse conjunto de 320 pontos foi dividido em conjunto de treino e teste na proporção de 70% e 30%, respectivamente. O treinamento, então, foi do tipo supervisionado. As variáveis preditivas dos

modelos foram as bandas do vermelho, verde e azul (RGB) das imagens. A variável alvo foi a classe cana-de-açúcar, erva-daninha ou solo exposto à qual o pixel correspondia. A métrica “exatidão global” foi utilizada para comparação entre as classificações obtidas por diferentes métodos no conjunto de dados reservado para teste. Após treinamento e teste dos modelos de classificação, foram geradas imagens da área total sendo os pixels classificados em: solo exposto, erva daninha e cana-de-açúcar. Essas imagens classificadas pelos algoritmos foram comparadas com a imagem do tipo verdade fundamental. Essa comparação permitiu avaliar com maior precisão a acurácia dos algoritmos.




FIGURA 1. a) Área agrícola cultivada com cana-de-açúcar no norte do Brasil; b) Zoom no campo cultivado com cana-de-açúcar com presença de ervas daninhas e solo exposto; c) Zoom na imagem do tipo verdade fundamental produzida por um biólogo especialista.

**RESULTADOS E DISCUSSÃO:** Quanto à análise da imagem capturada por drone foram obtidos resultado de exatidão global alcançada pelos distintos métodos de classificação entre 81,9% e 83,8% (Figura 2). A exatidão foi alta pois boa parte da área agrícola possui solo exposto. As características espectrais desse alvo são bem distintas das características espectrais das plantas, sendo mais fácil a sua classificação. Como uma quantidade considerável de pixel corresponde ao solo exposto, a sua classificação corretamente elevou o valor da exatidão global. No geral, os algoritmos conseguiram separar as classes de solo das classes das plantas. No entanto, houve dificuldade na distinção entre erva daninha e cana-de-açúcar (Figura 3).

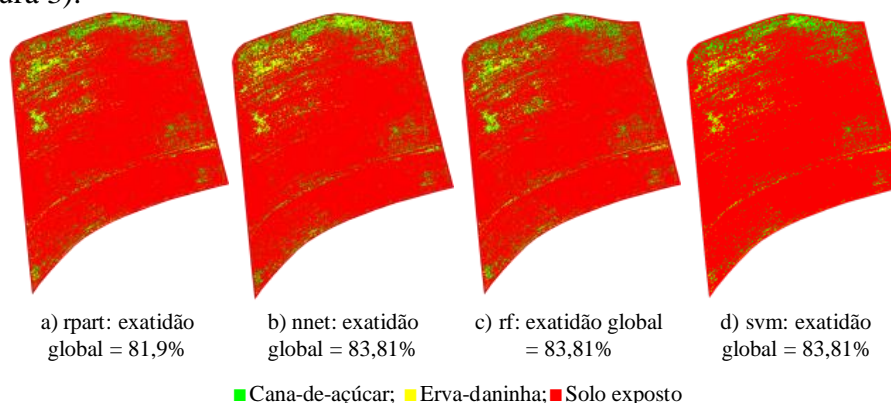


FIGURA 2. Resultados da classificação por diferentes métodos: árvore de decisão (rpart), floresta aleatória (rf), rede neural artificial (nnet) e máquina de vetor de suporte (svm).

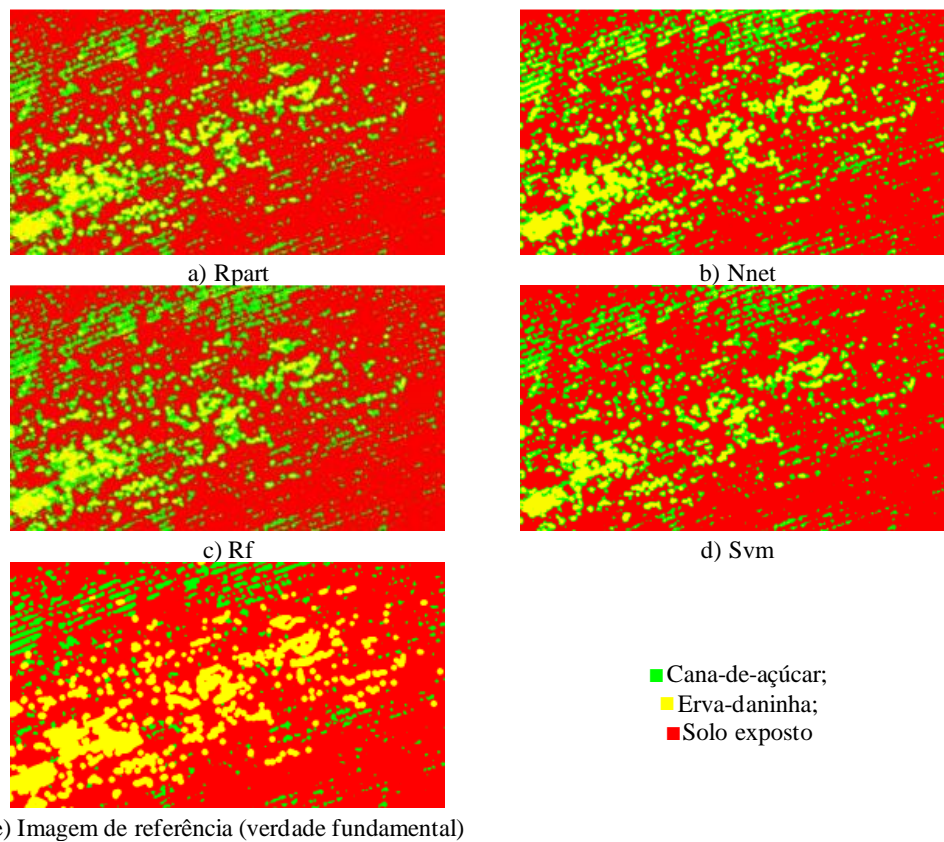


FIGURA 3. Zoom nas imagens após classificação em cana-de-açúcar, erva daninha e solo exposto pelos métodos: a) árvore de decisão (rpart); b) rede neural artificial (nnet); c) floresta aleatória (rf); e d) máquina de vetor de suporte (svm). e) Imagem de referência classificada por um biólogo especialista e considerada como verdade fundamental.

**CONCLUSÕES:** Os métodos avaliados apresentam potencial para auxiliar no manejo localizado de culturas, mas ainda demandam refinamentos para melhor distinguir as classes de interesse.

**AGRADECIMENTOS:** Agradecemos a Fundação de Amparo a Ciência e Tecnologia do Estado de Pernambuco (FACEPE) e a Universidade Federal Rural de Pernambuco pelo apoio.

**REFERÊNCIAS:** BAH, M. DIAN; HAFIANE, ADEL; CANALS, RAPHAEL. Deep learning with unsupervised data labeling for weed detection in line crops in UAV images. **REMOTE SENSING**, v. 10, n. 11, p. 1690, 2018.

JURADO-EXÓSITO, M. et al. Multi-species weed spatial variability and site-specific management maps in cultivated sunflower. **WEED SCIENCE**, v. 51, n. 3, p. 319-328, 2003.

MONTEIRO, A.A.O; VON WANGENHEIM, A. Orthomosaic Dataset of RGB aerial Images for Weed Mapping. LAPIX/UFSC. **INCoD Datasets Repository**. 2019. Disponível em: <http://www.lapix.ufsc.br/weed-mapping-sugar-cane> Acessado em: 31 de maio de 2023.

SOLTANI, N. et al. Potential yield loss in sugar beet due to weed interference in the United States and Canada. **WEED TECHNOLOGY**, v. 32, n. 6, p. 749-753, 2018.

STOREY, G.; MENG, Q.; LI, B. Leaf Disease Segmentation and Detection in Apple Orchards for Precise Smart Spraying in Sustainable Agriculture. **SUSTAINABILITY**, v. 14, n. 3, p. 1458, 2022.