

DETECÇÃO DE PRAGAS EM PLANTAÇÕES DE MANDIOCA USANDO MACHINE LEARNING E CLASSIFICAÇÃO DE IMAGENS

**Natássia Medeiros Rafaelle Siqueira¹; João Inácio Moreira Bezerra²; Leticia Barros
Dias Soares³; Marlon Mauricio Hernandez Cely⁴; Daniel Palomino⁴**

¹ Doutoranda em Ciência da Computação – Universidade Federal de Pelotas. Pelotas – RS. E-mail: nrmsiqueira@inf.ufpel.edu.br

² Doutorando em Ciência da Computação - Universidade Federal de Pelotas. Pelotas - RS.

³ Graduanda em Matemática - Universidade Federal de Pelotas. Pelotas - RS.

⁴ Professor na Universidade Federal de Pelotas - Pelotas, RS.

RESUMO

Pragas e doenças comprometem a produção agrícola, tornando necessários métodos eficientes de monitoramento. Este estudo propõe um sistema de diagnóstico de pragas em lavouras de mandioca, utilizando a arquitetura de machine learning ConvNeXt para classificar imagens em cinco classes: Mancha bacteriana, Mancha marrom, Ácaro-verde, Saudável e Mosaico. As imagens foram coletadas em fazendas de Sunyani, Gana, entre outubro e dezembro de 2022. A validação cruzada resultou em uma acurácia média de 91,80% ± 0,83%, com todas as classes apresentando desempenho acima de 90%, evidenciando a eficácia do modelo na identificação precoce de pragas em lavouras de mandioca.

1. INTRODUÇÃO

A agricultura mundial enfrenta ameaças de pragas que reduzem a produtividade e a qualidade dos cultivos, enquanto o uso excessivo de pesticidas eleva custos e riscos ambientais e à saúde. O aprendizado de máquina, aliado a sensores inteligentes, permite a detecção precoce e o manejo sustentável das infestações (WANG, 2025; MITTAL, 2024). A eficácia dessas abordagens depende da disponibilidade de dados, como demonstrado por Mensah (2023) ao coletar imagens de diferentes cultivos em Sunyani, Gana. Nesse cenário, este estudo propõe um sistema de diagnóstico de pragas em mandioca no Rio Grande do Sul (DA COSTA, 2024), utilizando a arquitetura ConvNeXt, que obteve alta acurácia na validação cruzada.

2. MATERIAL E MÉTODOS

O conjunto de dados disponibilizado por Mensah (2023) reúne imagens de pragas que afetam diferentes culturas agrícolas, incluindo castanha de caju, mandioca, milho e tomate. Neste estudo, foi selecionada apenas a parte referente às plantações de mandioca, composta pelas seguintes categorias: mancha bacteriana, mancha marrom, ácaro-verde, saudável e mosaico. A Figura 1 ilustra exemplos de cada categoria, enquanto a Figura 2 apresenta a distribuição do número de imagens por classe.




Figura 1: tipos de pragas na plantação, em ordem: mancha bacteriana, mancha marrom, ácaro-verde, saudável e mosaico.

A arquitetura ConvNeXt (TODI et al., 2023) foi escolhida por superar outras redes de classificação de imagens, como EfficientNet, ShuffleNet, MobileNet, DenseNet e Swin Transformer. Os experimentos foram conduzidos em Python, utilizando o modelo da biblioteca *torchvision.models*. Para assegurar a generalização e evitar sobreajuste, aplicou-se validação cruzada com 10 folds, distribuindo os dados em 70% para treinamento, 15% para validação e 15% para teste.




Figura 2: número de imagens por classe - plantações de mandioca.

3. RESULTADOS E DISCUSSÃO

Modelos pré-treinados têm mostrado alto desempenho na detecção de pragas e doenças em plantas, com acurácias variando de 83,2% (PATTNAIK et al., 2020) a 99,4% (MOHANTY et al., 2016). O ConvNeXt deste estudo alcançou 91,8% ($\pm 0,83$ pp) em validação cruzada, resultado competitivo, próximo ao de Wang et al. (2025) e superior ao de Xing et al. (2022), ainda que inferior aos valores mais altos de Mohanty et al. (2016) e Rao et al. (2021). A análise por classe (Figura 3) confirma a robustez do modelo, embora confusões entre sintomas semelhantes indiquem a necessidade de aprimoramentos com *data augmentation* e mecanismos de atenção.




Figura 3: Matriz de confusão do método ConvNeXt.

4. CONCLUSÃO

O modelo ConvNeXt obteve **91,9% de acurácia média** na validação cruzada, demonstrando eficiência na identificação de pragas e plantas saudáveis. Os resultados indicam potencial de aplicação como ferramenta de apoio ao monitoramento agrícola, favorecendo a detecção precoce de infestações e a redução de perdas na produção.

5. REFERÊNCIAS

DA COSTA, Liege Camargo et al. Consórcio de mandioca e feijão na potencialização da Agricultura Familiar do Rio Grande do Sul, Brasil. **Research, Society and Development**, v. 13, n. 1, p. e3413144731-e3413144731, 2024.

MENSAH, Patrick Kwabena et al. CCMT: Dataset for crop pest and disease detection. **Data in Brief**, v. 49, p. 109306, 2023.

MITTAL, Mamta et al. Machine learning for pest detection and infestation prediction: A comprehensive review. **Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery**, v. 14, n. 5, p. e1551, 2024.

MOHANTY, S.P.; Hughes, D.P.; Salathé, M. **Using Deep Learning for Image-Based Plant Disease Detection**. Front. Plant Sci. 2016, 7, 1419.

PATTNAIK, G.; Shrivastava, V.K.; Parvathi, K. **Transfer Learning-Based Framework for Classification of Pest in Tomato Plants**. Appl. Artif. Intell. 2020, 34, 981–993.

SANATH RAO, U.; Swathi, R.; Sanjana, V.; Arpitha, L.; Chandrasekhar, K.; Chinmayi; Naik, P.K. **Deep Learning Precision Farming: Grapes and Mango Leaf Disease Detection by Transfer Learning**. Glob. Transit. Proc. 2021, 2, 535–544.

TODI, Agastya et al. Convnext: A contemporary architecture for convolutional neural networks for image classification. In: **2023 3rd International Conference on Innovative Sustainable Computational Technologies (CISCT)**. IEEE, 2023. p. 1-6.

WANG, Shaohua et al. Advances in deep learning applications for plant disease and pest detection: A review. **Remote Sensing**, v. 17, n. 4, p. 698, 2022

XING, S.; Lee, H.J. **Crop Pests and Diseases Recognition Using DANet with TLDP**. Comput. Electron. Agric. 2022, 199, 107144.