

DETECÇÃO DE PRAGAS EM LAVOURAS COM REDES NEURAIAS CONVOLUCIONAIS EM SISTEMAS EMBARCADOSMaria Edduarda Vinhas Lara¹ (IC), Bruno Guazzelli Batista (PQ)¹¹Universidade Federal de Itajubá.**Palavras-chave:** Agricultura; Drones; Inteligência Artificial.**Introdução**

A Agricultura 4.0 representa uma nova era na produção agrícola, marcada pela integração de tecnologias, utilizando ferramentas que permitem a coleta massiva de dados e o monitoramento em tempo real de lavouras [Andrade et al. 2021, Kamilaris and Prenafeta-Boldu 2018]. Isto possibilita a tomada de decisões mais precisas, sustentáveis e economicamente eficientes [Ribeiro et al. 2022].

Um dos principais problemas nesse cenário é a identificação precoce de pragas e doenças foliares. O diagnóstico tradicional, baseado em inspeção manual, é demorado e inviável em grandes áreas.

Este artigo tem o objetivo de desenvolver e avaliar um sistema automático de detecção de pragas e doenças foliares, utilizando Redes Neurais Convolucionais (CNNs) em dispositivos com recursos limitados como Raspberry Pi 5, integrada a drones para a captura aérea de imagens em plantações de café, tomate e pimentão. O pipeline implementado inclui módulos para divisão balanceada dos conjuntos de dados, utilizando a técnica *under-sampling*, treinamento de modelos compactos e análise de desempenho em hardware embarcado. Foram utilizados dois datasets distintos — *Coffee* [Abdulazeem 2025] e *PlantVillage* [Hughes and Salathe 2015] — totalizando mais de 70 mil imagens rotuladas.

As principais contribuições deste estudo incluem:

- A implementação de um pipeline automatizado para todo o processo de divisão de dados, treinamento e teste, com métricas salvas em planilhas;
- A análise de CNNs em dispositivos de baixo custo, considerando tempo de processamento, acurácia e consumo de recursos;
- A demonstração da viabilidade do uso de soluções baseadas em IA embarcada, acessíveis e de fácil replicação, para a agricultura de precisão, o que contribui para a identificação

precoce de pragas e doenças foliares em escala comercial.

Metodologia

Foram realizados experimentos preliminares com a arquitetura AlexNet [Krizhevsky et al. 2012] para avaliar o seu desempenho, mas as limitações de recursos em hardware embarcado mostraram sua inviabilidade prática, levando ao desenvolvimento de uma CNN própria, mais leve e otimizada, voltada para aplicações em agricultura de precisão, especialmente em cenários de monitoramento aéreo com drones.

Outras arquiteturas mais profundas e robustas, como ResNet [He et al. 2016] e YOLO [Redmon et al. 2016], também foram consideradas, mas foram descartadas por demandarem maior capacidade computacional, incompatível com a execução em dispositivos de baixo custo como a Raspberry Pi 5.

Em seguida, selecionou-se dois conjuntos de dados — *Coffee Dataset* e *PlantVillage* —, divididos em 60% dos dados utilizados para treinamento, 20% para validação e 20% para teste. Inicialmente, avaliou-se o uso de pesos dinâmicos na função de perda para lidar com o desbalanceamento entre classes, mas essa abordagem apresentou instabilidade nos gradientes. Como alternativa, aplicou-se o balanceamento por *under-sampling* para igualar o número de imagens em todas as classes.

- ***Coffee Dataset***: contém 58.555 imagens de folhas de cafeeiro classificadas em cinco categorias distintas: *Cercospora*, *Phoma*, *Leaf Miner*, *Leaf Rust* e folhas saudáveis. As imagens foram capturadas em ambiente real, com diferentes níveis de iluminação, ângulo e foco, o que confere maior complexidade e realismo ao conjunto [Abdulazeem 2025].
- ***PlantVillage Dataset***: composto por 13.474 imagens rotuladas de folhas de tomate, pimentão e batata, distribuídas entre 15 classes distintas. Trata-se de um dataset amplamente

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

utilizado em pesquisas relacionadas à agricultura de precisão, devido à sua variedade de culturas e diversidade de doenças documentadas [Hughes and Salathe 2015].

Esses conjuntos foram escolhidos por sua relevância e qualidade de anotação, bem como pela diversidade de espécies vegetais e sintomas foliares representados. Eles possibilitam avaliar o desempenho dos modelos em contextos distintos, desde imagens de campo com ruído real até imagens mais controladas.

Com os dados preparados, a CNN foi implementada no *Visual Studio Code*, em Python 3.11, usando *TensorFlow/Keras*¹ e bibliotecas auxiliares (*NumPy*², *Pandas*³, *scikit-learn*). A arquitetura contou com três camadas convolucionais com ReLU, *max pooling* 2×2 e camada densa final com *softmax*. O modelo foi treinado por 10 a 20 épocas e validado em um computador, antes de ser migrado para a Raspberry Pi 5 para testes em ambiente de baixo custo. A Tabela 1 apresenta as especificações do dispositivo utilizado.

Tabela 1. Especificações do computador utilizado para treinamento.

Componente	Especificação
Fabricante	ASUS
Processador	Intel Core i5
Memoria RAM	4 GB
Armazenamento	SSD de 238 GB
Placa de video integrada	128 MB
Sistema Operacional	Windows 11

Após a validação preliminar, cujos resultados demonstraram acurácias superiores a 85% nos testes com os conjuntos de dados utilizados, os modelos foram migrados para a Raspberry Pi 5, equipada com sistema operacional Ubuntu 20.04. A execução embarcada permitiu avaliar o desempenho dos modelos em hardware de baixo custo, alinhado a aplicações agrícolas em campo.

Por fim, todo o processo foi integrado a um pipeline automatizado dividido em três módulos: (1) balanceamento e separação de dados; (2) treinamento e salvamento do modelo; (3) teste e registro das métricas, incluindo acurácia, tempo de inferência, tempo por imagem, uso de memória e tabela de acertos/erros por classe.

Resultados e discussão

De acordo com as Tabelas 2, 3 e 4, os modelos treinados com o *dataset Coffee* tiveram o melhor desempenho em todos os cenários, chegando a 99,98% de acurácia, tanto no computador quanto na Raspberry Pi 5. Isso se deve ao fato de ter apenas 5 classes e imagens mais homogêneas, facilitando o aprendizado das CNNs.

Já com o *dataset PlantVillage*, que possui 15 classes e maior diversidade visual, as acurácias foram mais baixas (entre 85,91% e 87,65%), exigindo mais épocas de treino para melhorar os resultados.

Mesmo no ambiente embarcado, o tempo de inferência se manteve ótimo, variando entre 83 ms e 92 ms por imagem, e o uso de memória ficou abaixo de 135 MB em todos os casos. No fim, obteve-se um sistema leve, preciso e fácil de adaptar em dispositivos como drones no monitoramento de diferentes culturas agrícolas, ajudando no diagnóstico precoce e na produtividade no campo.

Tabela 2. Resultados dos treinamentos dos modelos CNN com diferentes datasets executados no computador.

10 Épocas					
Dataset	Classes	Imagens	Acurácia	Mem. (MB)	Tempo (s)
PlantVillage	15	4139	83,09%	249,78	374,53
Coffee	5	11533	99,80%	218,09	927,44
20 épocas					
PlantVillage	15	4139	78,32%	212,68	670,73
Coffee	5	11533	99,98%	205,09	843,64

¹ <https://www.tensorflow.org/>. Acesso em: 19 ago. 2025.

² <https://numpy.org/>. Acesso em: 19 ago. 2025.

³ <https://pandas.pydata.org/>. Acesso em: 19 ago. 2025.

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

Tabela 3. Resultados dos testes dos modelos CNN com diferentes datasets executados na plataforma Raspberry Pi 5.

10 Épocas				
Dataset	Classes	Imagens	Acurácia	Memória (MB)
PlantVillage	15	4139	85,91%	104,23
Coffee	5	11533	99,98%	132,32
20 épocas				
PlantVillage	15	4139	87,65%	104,00
Coffee	5	11533	99,98%	116,85

Tabela 4. Resultados dos testes dos modelos CNN com diferentes datasets e 20 épocas executados no computador.

Dataset	Classes	Imagens	Acurácia	Memória (MB)
PlantVillage	15	13474	87,65%	99,12
Coffee	5	57635	99,98%	110,70

Conclusões

Este trabalho demonstrou a viabilidade do uso de redes neurais convolucionais leves para a detecção automática de pragas e doenças em folhas de lavouras, com foco em culturas de café, tomate e pimentão. Através da criação de um pipeline automatizado e modular, foi possível realizar a divisão balanceada dos dados, o treinamento eficiente dos modelos e a avaliação sistemática dos resultados.

Os testes indicaram que mesmo modelos compactos, quando bem otimizados, podem atingir acurácias superiores a 85% e operar com desempenho satisfatório em dispositivos de baixo custo, como a Raspberry Pi 5. Isso confirma o potencial de soluções embarcadas com inteligência artificial como ferramentas acessíveis e eficazes para a agricultura de precisão.

Além de contribuir para a identificação precoce de doenças foliares, o sistema desenvolvido pode ser integrado a plataformas móveis como drones, ampliando ainda mais sua aplicabilidade em campo. Futuros

trabalhos podem explorar técnicas de aumento de dados, arquiteturas mais sofisticadas e treinamento contínuo para aprimorar ainda mais a robustez e a generalização do modelo.

Agradecimentos

Agradeço à UNIFEI por todo o suporte acadêmico, pela infraestrutura disponibilizada e pelo ambiente de aprendizado que foi essencial para o desenvolvimento deste trabalho.

À Fapemig, pela concessão da bolsa de estudos e pelo incentivo à pesquisa científica e tecnológica, possibilitando a dedicação necessária para a realização deste projeto.

Estendo meus agradecimentos aos professores e colegas que contribuíram com ideias, sugestões e apoio.

Referências

- ABDULAZEEM, N. *Jmuben coffee dataset*. [S.l.: s.n.], 2025. Disponível em: <https://github.com/jmuben/coffee-dataset>. Acesso em: 10 abr. 2025.
- ANDRADE, S. *et al.* O papel dos drones na agricultura 4.0 e 5.0: auxílio tecnológico para uma agricultura eficiente, produtiva e sustentável. [S.l.: s.n.], 2021.
- ES-SAADY, Y. *et al.* Deep learning for plant disease detection and diagnosis: a review. *Computers and Electronics in Agriculture*, v. 180, 2021.
- FERNANDEZ, A.; GARCÍA, S.; HERRERA, F. Learning from imbalanced data sets. *Springer Handbook of Computational Intelligence*, p. 477–496, 2018.
- HE, H.; GARCIA, E. A. Learning from imbalanced data. *IEEE Transactions on Knowledge and Data Engineering*, v. 21, n. 9, p. 1263–1284, 2009.
- HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. In: *PROCEEDINGS OF THE IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR)*, 2016. p. 770–778.
- HUGHES, D. P.; SALATHÉ, M. An open access repository of images on plant health to enable the development of mobile disease diagnostics. *arXiv preprint*, arXiv:1511.08060, 2015.
- KAMILARIS, A.; PRENAFETA-BOLDU, F. X. Deep learning in agriculture: a survey. *Computers and Electronics in Agriculture*, v. 147, p. 70–90, 2018.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E.

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

Imagenet classification with deep convolutional neural networks. In: *ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS*, v. 25, p. 1097–1105, 2012.

LEE, J.; SARAOGI, A. Deep convolutional neural network-based autonomous drone navigation. *arXiv preprint*, arXiv:1905.01657, 2019. Disponível em: <https://arxiv.org/abs/1905.01657>. Acesso em: 10 abr. 2025.

MICROSOFT CORPORATION. *Visual Studio Code*. [S.l.: s.n.], 2024. Disponível em: <https://code.visualstudio.com/>. Acesso em: 26 jun. 2025.

REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. You only look once: unified, real-time object detection. In: *PROCEEDINGS OF THE IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR)*, 2016. p. 779–788.

RIBEIRO, J. *et al.* Uso de drones para aplicações de defensivos agrícolas. In: *VIII JORNADA CIENTÍFICA E TECNOLÓGICA DA FATEC DE BOTUCATU*, 2022.