

DETECÇÃO DE PRAGAS EM PLANTAÇÕES DE CASTANHA DE CAJU USANDO MACHINE LEARNING COM SWIN TRANSFORMERS

**João Inácio Moreira Bezerra¹; Natássia Medeiros Rafaelle Siqueira²; Sofia Pagliarini³;
Jairo Valões de Alencar Ramalho⁴; Marlon Mauricio Hernandez Cely⁴**

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

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

³ Graduanda em Engenharia de Controle e Automação - Universidade Federal de Pelotas. Pelotas - RS.

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

RESUMO

Pragas e doenças comprometem a produção agrícola, exigindo métodos eficientes de monitoramento. Este trabalho propõe um sistema de diagnóstico de pragas em castanhas de caju usando a arquitetura de machine learning Swin Transformer para classificar imagens em cinco classes: Antracnose, Gomose, Saudável, Bicho-mineiro e Ferrugem-Vermelha. As imagens foram obtidas de fazendas em Sunyani, Gana, entre outubro e dezembro de 2022. Aplicou-se validação cruzada com 10 folds, obtendo uma acurácia média de 96,40% ± 0,57%, com todas as classes apresentando acurácia acima de 93%, demonstrando assim a eficácia do modelo na identificação precoce de pragas.

1. INTRODUÇÃO

A demanda global por alimentos deverá crescer cerca de 75% até 2050 para suprir uma população estimada em 9,7 bilhões de pessoas. No entanto, pragas e doenças continuam sendo um grande desafio, responsáveis por reduzir em média 38% da produção agrícola, podendo causar perdas de até 99% em regiões em desenvolvimento (MENSAH, 2023). Diante desse cenário, torna-se essencial desenvolver estratégias inovadoras para mitigar os impactos das pragas e garantir a segurança alimentar mundial.

Uma dessas estratégias tem sido o uso de técnicas de inteligência artificial (WANG, 2025), capazes de auxiliar na detecção precoce de pragas e doenças em plantas. A partir da análise de padrões visuais em folhas, caules, flores e frutos, esses métodos permitem identificar sintomas ainda em estágios iniciais, favorecendo ações rápidas e eficazes no manejo agrícola. Para utilizar métodos de inteligência artificial, são necessários dados, e neste contexto, Mensah (2023) disponibilizou uma base de dados para classificar a presença de pestes em diferentes plantações, com a presença de diferentes pragas para cada plantação, com a base de dados sendo composta por imagens, obtidas durante o período de entressafra em fazendas de Sunyani, Gana entre Outubro de 2022 e Dezembro de 2022.

Neste contexto, este trabalho propõe um sistema de diagnóstico de pragas em plantações de castanhas de caju, utilizando a base de dados disponibilizada por Mensah (2023). Este sistema utiliza uma arquitetura Swin Transformer (TSAI, 2023) para classificar as imagens quanto à presença de determinados tipos de pragas, obtendo uma acurácia geral média ao longo dos 10 *folds* de validação cruzada.

2. MATERIAL E MÉTODOS

A base de dados disponibilizada por Mensah (2023) possui imagens relativas à presença de pragas nos seguintes tipos de plantações: Castanhas de Caju, Mandioca, Milho e Tomates. Para este trabalho específico, usa-se a base de dados relativas às plantações de castanhas de caju, que são compostas pelas seguintes pragas: antracnose, gomose, saudáveis (plantas sem a presença de praga), bicho-mineiro e ferrugem vermelha. A Figura 1 mostra imagens de cada tipo de praga, enquanto o número de imagens para cada classe é dado pela Figura 2.



Figura 1: tipos de pragas na plantação, em ordem: antracnose, gomose, saudável, bicho-mineiro e ferrugem vermelha.

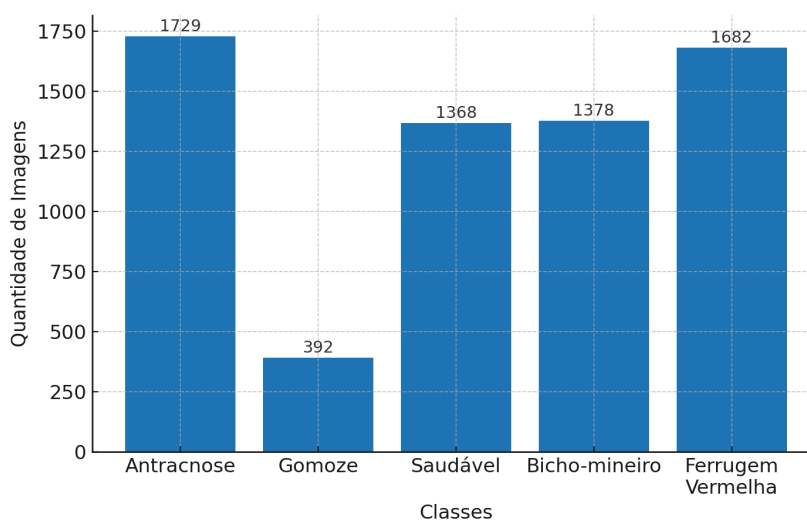


Figura 2: número de imagens por classe - plantações de castanha de caju.

A arquitetura de classificação de imagens Swin Transformer, com os parâmetros padrões do modelo (TSAI, 2023), foi selecionada por apresentar desempenho superior à outras arquiteturas do estado da arte de classificação de imagens, tais como Resnet50, ShuffleNet, GoogLeNet, DenseNet e Vision Transformer. Os experimentos foram realizados na linguagem de programação Python, com o modelo sendo importado da biblioteca *torchvision.models*. A fim de garantir a capacidade de generalização do modelo, evitando sobre-ajuste, foi utilizada validação cruzada, rodando o experimento por 10 rodadas, ou *folds*, sendo que em cada rodada, as imagens utilizadas para treinamento (70%), validação (15%) e teste (15%) são diferentes.

3. RESULTADOS E DISCUSSÃO

Ao longo das 10 rodadas de validação cruzada, o modelo apresentou uma acurácia (número de previsões corretas dividido pelo número total de previsões) média

de 96.40%, com um desvio padrão de 0.57%. Na Figura 3, apresenta-se a matriz de confusão do modelo, considerando as seguintes classes: AN (Antracnose), GO (Gomose), SA (Saudável), BM (Bicho-mineiro) e FV (Ferrugem-Vermelha). Observa-se que o modelo tem ótimo desempenho em todas as classes, com a pior acurácia sendo de 93% no diagnóstico de antracnose.




Figura 3: Matriz de confusão do método Swin Transformer.

4. CONCLUSÃO

O modelo Swin Transformer apresentou alta precisão (96,4%) na classificação de pragas e plantas saudáveis em lavouras de castanhas de caju, mostrando potencial como ferramenta de monitoramento agrícola para detecção precoce e redução de perdas.

5. REFERÊNCIAS

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

TSAI, Chi-Yi; SHEN, Guan-Yu; NISAR, Humaira. Swin-jde: Joint detection and embedding multi-object tracking in crowded scenes based on swin-transformer. **Engineering Applications of Artificial Intelligence**, v. 119, p. 105770, 2023.

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, 2025.