

CLASSIFICAÇÃO DE DEFEITOS EM AMEIXAS AFRICANAS USANDO REDE NEURAL CONVOLUCIONAL PRÉ-TREINADAAmanda C. Soares¹ (IC), Matheus B. Francisco (PQ)¹¹Universidade Federal de Itajubá**Palavras-chave:** Classificação automatizada. Inspeção por imagem. Inteligência artificial. Visão computacional.**Introdução**

A inspeção da qualidade de frutas desempenha um papel fundamental na cadeia de produção e comercialização agrícola, impactando diretamente na aceitação do produto pelo consumidor e na redução de perdas pós-colheita. Tradicionalmente, esse processo tem sido realizado manualmente, o que torna a avaliação sujeita a erros humanos, variações subjetivas e altos custos operacionais (Fadja et al., 2025).

Nesse contexto, a aplicação de técnicas de Visão Computacional e Inteligência Artificial tem se mostrado uma alternativa promissora para automatizar e padronizar a classificação de defeitos em frutas (Fadja et al., 2024).

As Redes Neurais Convolucionais (CNNs) são amplamente reconhecidas como o estado da arte para tarefas de análise de imagens, devido à sua capacidade de extrair automaticamente características relevantes e identificar padrões complexos em dados visuais. Elas se destacam em aplicações como reconhecimento facial, diagnósticos por imagem médica e detecção de objetos, oferecendo alto desempenho mesmo em cenários desafiadores.

No entanto, seu uso nem sempre é necessário ou vantajoso — especialmente em problemas mais simples, nos quais algoritmos clássicos de visão computacional, como métodos de limiarização, detecção de bordas ou descritores de características como HOG e SIFT, podem ser suficientes para alcançar bons resultados com menor custo computacional.

Para problemas de baixa complexidade ou tarefas com estruturas visuais bem definidas, modelos mais simples tendem a ser mais eficientes, exigindo menos dados, menor poder de processamento e oferecendo maior facilidade de interpretação. Por outro lado, em cenários mais complexos, com variações de iluminação, ruídos, múltiplas classes ou padrões sutis, as CNNs geralmente superam os métodos tradicionais — embora isso envolva maior custo computacional e tempos de treinamento mais longos.

Portanto, a escolha do algoritmo ideal depende diretamente da complexidade do problema, dos recursos disponíveis e dos requisitos de desempenho — tornando essencial ponderar a relação custo-benefício antes de optar por arquiteturas mais sofisticadas (Kattenborn et al., 2021).

Este trabalho propõe a construção e avaliação de uma CNN para a classificação automática de defeitos em imagens de *African Plums* (ameixas africanas), utilizando um conjunto de dados público disponível na plataforma Kaggle. O dataset inclui seis categorias distintas: amassada, rachada, podre, manchada, intacta e verde.

O principal objetivo deste estudo é desenvolver um modelo de aprendizado profundo capaz de identificar corretamente o tipo de defeito presente nas frutas, contribuindo para a automação da triagem e controle de qualidade no setor agroindustrial. Outros estudos sobre essa área são apresentados na Tabela 1.

Tabela 1. Estudos importantes

Descrição		
Autor	Objetivo	Modelo
Gill et al. (2022)	Reconhecimento de frutas (maçã, goiaba e laranja)	CNN, RNN e LSTM
Fonseca et al. (2023)	Sistema de seleção de ameixa	CNN
Bhowmik et al. (2024)	Classificação da doença da folha da ameixeira	Vision Transformers
Amin et al. (2023)	Classificação de frescor de frutas	CNN e AlexNet
Fadja et al. (2024)	Detecção de defeitos em ameixa africana	Transfer learning

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

Nalan et al. (2025)	Previsão de rendimento agrícola	Transformer - CNN
---------------------	---------------------------------	-------------------

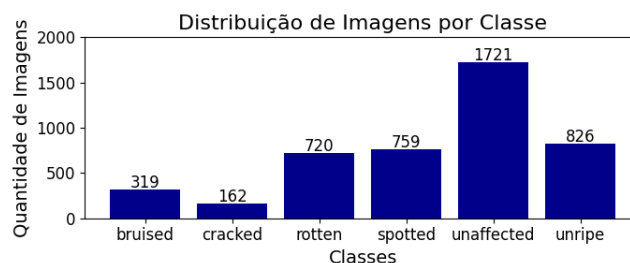
defeito identificado: amassada, rachada, podre, manchada, intacta e verde.

Figura 1 – Exemplo de imagens por classes



A primeira etapa da análise foi verificar a distribuição das imagens por classe, com o objetivo de identificar se o conjunto era balanceado. O resultado mostrou exatamente o oposto: havia um desequilíbrio significativo, como ilustrado na Figura 2.

Figura 2 – Distribuição das imagens por classes



C. Preparação dos Dados

Para corrigir o desbalanceamento entre classes, foi criado um novo conjunto de dados balanceado por meio de oversampling com data augmentation, utilizando o *ImageDataGenerator*. Esse objeto aplicou transformações nas imagens originais, como rotação, deslocamento, zoom, entre outras, gerando variações artificiais. Em seguida, os dados foram divididos aleatoriamente em subconjuntos de treinamento (60%), validação (30%) e teste (10%).

D. Modelagem

A modelagem foi realizada utilizando a arquitetura YOLOv11n, adaptada para tarefas de classificação de imagens por meio da biblioteca Ultralytics. O modelo pré-treinado foi carregado e treinado com os dados balanceados em um total de 80 épocas, com imagens redimensionadas para 224x224

Metodologia

Trabalhar com dados requer organização e estruturação. Assim, foi escolhida a metodologia CRISP-DM, composta por seis etapas: compreensão do problema, compreensão dos dados, preparação dos dados, modelagem, validação e implementação.

Essa abordagem permite organizar o trabalho de forma lógica, garantindo que os dados sejam tratados corretamente e atendam às necessidades do projeto.

A. Compreensão do Problema

Classificar defeitos em produtos agrícolas é uma tarefa complexa, especialmente pela subjetividade e o grande volume de produção. A inspeção manual é repetitiva, cansativa e propensa a erros, dificultando decisões rápidas e precisas. A análise dos defeitos é essencial para identificar causas e evitar perdas. Nesse contexto, a automação com inteligência artificial surge como uma solução eficiente, confiável e escalável.

B. Compreensão dos Dados

O conjunto de dados utilizado neste trabalho está disponível na plataforma Kaggle e foi desenvolvido por Arnaud Nguembang Fadja e Armel Gabin Fameni Tagni. Ele contém 4.507 imagens anotadas de ameixas africanas (*African plums*), coletadas em diferentes campos de cultivo em Camarões.

Esse conjunto foi especificamente elaborado para treinar e avaliar modelos de inteligência artificial voltados à avaliação da qualidade das frutas e detecção de defeitos. As imagens, conforme a figura 1 estão organizadas em seis classes, de acordo com o tipo de

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

pixels e tamanho de lote igual a 32. A taxa de aprendizado inicial foi definida como 0,01, sendo aplicado critério de parada antecipada com paciência de cinco épocas. O treinamento ocorreu em GPU, e ao final o modelo ajustado foi salvo para posterior avaliação. A escolha pela arquitetura YOLOv11n se deu por sua leveza e eficiência, características importantes para aplicações em ambientes com restrição de recursos computacionais.

E. Validação

A validação do desempenho do modelo foi conduzida continuamente ao longo do treinamento, por meio do acompanhamento das métricas de perda (*loss*) e acurácia (*accuracy*), tanto nos conjuntos de treinamento quanto de validação. Essas métricas foram registradas a cada época e visualizadas por meio de gráficos, permitindo o acompanhamento da evolução do aprendizado e a identificação de possíveis sinais de *overfitting*.

Além disso, foi realizada uma análise qualitativa complementar utilizando imagens do conjunto de teste. Para essa etapa, uma imagem representativa de cada classe foi selecionada de forma aleatória e embaralhada, e foram feitas previsões sobre elas. Em seguida, os resultados foram comparados com os rótulos reais, e também foi exibido o nível de confiança atribuído pelo modelo a cada previsão.

Essa abordagem permitiu avaliar, de forma visual e interpretável, a capacidade de generalização do modelo diante de dados inéditos.

F. Implantação


A aplicação de redes neurais convolucionais no setor agrícola permite automatizar o monitoramento e a classificação de defeitos em alimentos, substituindo processos manuais e subjetivos por sistemas mais rápidos, precisos e escaláveis. Essa tecnologia, baseada em inteligência artificial, pode ser usada no campo ou em linhas de produção, aumentando a eficiência do controle de qualidade e melhorando as condições de trabalho.

Resultados e discussão

Utilizando o modelo YOLOv11n, foi possível obter uma acurácia de 89% na tarefa de classificação das seis classes analisadas. Esse resultado é considerado satisfatório, especialmente diante do fato de que as diferenças entre as classes são sutis nas imagens, o que

tornaria a classificação uma tarefa desafiadora até mesmo para um ser humano. A rede neural convolucional demonstrou um desempenho consistente, sendo capaz de identificar padrões visuais com precisão. Ademais, foi realizado o monitoramento contínuo das curvas de acurácia e perda durante o treinamento, com o objetivo de identificar possíveis indícios de *overfitting*. Conforme ilustrado na Figura 3, observa-se que as curvas não apresentaram esse comportamento, indicando um bom equilíbrio entre o aprendizado e a generalização do modelo.

Figura 3 – Gráficos das curvas no treino e validação



Além disso, a matriz de confusão, apresentada na Figura 4, mostra que o modelo obteve um desempenho bastante equilibrado entre as diferentes classes, com altos valores na diagonal principal, indicando uma taxa elevada de acertos.


Figura 4 – Matriz de Confusão



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

Contudo, houve algumas confusões pontuais entre classes visualmente semelhantes, como "bruised" e "rotten", ou ainda "spotted" e "unaffected", o que é esperado devido à sobreposição de características visuais. No entanto, esses erros não comprometeram significativamente a precisão geral do modelo, evidenciando sua robustez e capacidade de discriminar padrões visuais mesmo diante de classes com características sutis. Portanto, ao realizar testes separadamente com as imagens do conjunto de teste, conforme mostrado na Figura 5, foi possível observar que o modelo se comportou de forma bastante satisfatória, realizando classificações com alta consistência.

Figura 5 – Exemplos de classificação



Conclusões

Diante dos resultados obtidos, conclui-se que a aplicação de redes neurais convolucionais, em especial o modelo YOLOv11n, mostrou-se eficaz para a tarefa de classificação automática de defeitos em ameixas africanas, alcançando acurácia de 89% mesmo diante de diferenças visuais sutis entre as 6 classes. A metodologia adotada, baseada na CRISP-DM, permitiu estruturar o desenvolvimento do projeto de forma sistemática, desde a preparação e balanceamento dos dados até a validação rigorosa do modelo. A análise das métricas e da matriz de confusão evidenciou a capacidade do modelo em generalizar o aprendizado, mesmo em um cenário de múltiplas classes e padrões

visuais semelhantes. Dessa forma, os resultados reforçam o potencial da inteligência artificial como ferramenta de apoio ao controle de qualidade no setor agrícola

Agradecimentos

Os autores agradecem à Universidade Federal de Itajubá pelo suporte institucional e acadêmico, e à FAPEMIG pelo apoio financeiro.

Referências

Amin, U., Shahzad, M. I., Shahzad, A., Shahzad, M., Khan, U., & Mahmood, Z. (2023). Automatic fruits freshness classification using CNN and transfer learning. *Applied Sciences*, 13(14), 8087.

Bhowmik, A. C., Ahad, M. T., Emon, Y. R., Ahmed, F., Song, B., & Li, Y. (2024). A customised Vision Transformer for accurate detection and classification of Java Plum leaf disease. *Smart Agricultural Technology*, 8, 100500.

Fadja, A. N., Che, S. R., & Atemkeng, M. (2024). Intelligent Vision System with Pruning and Web Interface for Real-Time Defect Detection on African Plum Surfaces. *Information*, 15(10), 635.

Fadja, A. N., Tagni, A. G. F., Che, S. R., & Atemkeng, M. (2025). A Dataset of Annotated African Plum Images from Cameroon for AI Based Quality Assessment. *Data in Brief*, 111351.

Fonseca, Y., Bautista, C., Pardo-Beainy, C., & Parra, C. (2023). A plum selection system that uses a multi-class Convolutional Neural Network (CNN). *Journal of Agriculture and Food Research*, 14, 100793.

Gill, H. S., Khalaf, O. I., Alotaibi, Y., Alghamdi, S., & Alassery, F. (2022). Multi-Model CNN-RNN-LSTM Based Fruit Recognition and Classification. *Intelligent Automation & Soft Computing*, 33(1).

Kattenborn, T., Leitloff, J., Schiefer, F., & Hinz, S. (2021). Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. *ISPRS journal of photogrammetry and remote sensing*, 173, 24-49.

Nalan, R., Ram, M. R., Nihal, H. M., Sasirekha, S. P., & Mekala, N. (2025, March). Region-based Crop Yield Prediction using a Transformer-CNN Hybrid Model for Agricultural Forecasting. In *2025 International Conference on Intelligent Computing and Control Systems (ICICCS)* (pp. 1536-1543). IEEE.