

Visão Computacional na Agricultura de Precisão: Uma Análise Comparativa de Arquiteturas CNN no Diagnóstico de Doenças Foliares do Milho

Jhonatas Gomes Ribeiro¹, Igor Bezerra Reis¹

¹Instituto Federal do Piauí – Corrente – Piauí – Brasil

jhonatasgomes2003@gmail.com, igor.bezerra@ifpi.edu.br

Abstract. *Corn is a pillar of Brazilian agribusiness, but its production is threatened by foliar diseases that demand rapid and accurate diagnosis. As a solution, this paper presents a comparative analysis of four Computer Vision architectures (InceptionV3, ResNet50, ResNet152, and DenseNet201) applied to the classification of these diseases, with a focus on the reality of the MATOPIBA region. The objective is to evaluate the performance and efficiency of each model to inform the development of an effective early detection tool capable of reducing costs, promoting sustainability, and increasing profitability for producers, in line with Brazil's Digital Sovereignty Plan.*

Resumo. *O milho é um pilar do agronegócio brasileiro, mas sua produção é ameaçada por doenças foliares que demandam diagnóstico rápido e preciso. Como solução, este artigo apresenta uma análise comparativa de quatro arquiteturas de Visão Computacional (InceptionV3, ResNet50, ResNet152 e DenseNet201) aplicadas à classificação dessas doenças, com foco na realidade da região do MATOPIBA. O objetivo é avaliar a performance e a eficiência de cada modelo para subsidiar o desenvolvimento de uma ferramenta de detecção precoce eficaz, capaz de reduzir custos, promover a sustentabilidade e aumentar a rentabilidade para os produtores, em linha com o Plano de Soberania Digital do Brasil.*

1. Introdução

O agronegócio brasileiro, com o milho sendo um de seus principais pilares, enfrenta um desafio crítico: as doenças foliares, como a ferrugem comum e a mancha cinzenta, que exigem um diagnóstico rápido e preciso para evitar perdas significativas [Jasrotia et al. 2023]. O problema principal reside no método de diagnóstico visual tradicional, que é lento, subjetivo e depende de conhecimento especializado [Ma et al. 2022]. Essa abordagem pode atrasar a tomada de decisão, comprometendo safras inteiras. A subjetividade da inspeção humana e seu alto custo evidenciam a necessidade de soluções tecnológicas que democratizem o acesso a diagnósticos de alta qualidade, otimizando o uso de defensivos e promovendo uma agricultura mais sustentável e rentável [Singh et al. 2024], especialmente em fronteiras agrícolas como a região do MATOPIBA (Maranhão, Tocantins, Piauí e Bahia).

Nesse cenário, a Inteligência Artificial, por meio da Visão Computacional, surge como uma alternativa para automatizar e aprimorar essa tarefa. Visando subsidiar o desenvolvimento de soluções eficazes, este trabalho apresenta uma análise

comparativa de quatro arquiteturas de Redes Neurais Convolucionais (CNNs) — InceptionV3 [Szegedy et al. 2016], ResNet50 e ResNet152 [He et al. 2016] e DenseNet201 [Huang et al. 2017]. O estudo busca identificar o modelo que oferece o melhor balanço entre acurácia e eficiência computacional, elemento crucial para sua aplicação prática na agricultura de precisão.

2. Metodologia

A metodologia é estruturada como um estudo comparativo para determinar a arquitetura de CNN mais eficaz para a tarefa proposta.

2.1. Dataset e Pré-processamento

Para este estudo, foi utilizado o conjunto de dados *Corn or Maize Leaf Disease Dataset* [Ghose and Others 2020], composto por 4188 imagens de folhas de milho, distribuído em quatro categorias: saudável, ferrugem comum (*common rust*), mancha cinzenta (*gray leaf spot*) e mancha foliar (*blight*).

O conjunto de dados foi dividido na proporção de 80% para treinamento e 20% para validação/teste. Como etapas de pré-processamento, todas as imagens foram redimensionadas para uma dimensão de 224x224 pixels e normalizadas. Para aumentar a diversidade dos dados de treino e mitigar o superajuste (*overfitting*), aplicou-se a técnica de *Data Augmentation* [Mumuni and Mumuni 2022], que incluiu transformações como rotações (até 40 graus), deslocamentos de largura e altura, cisalhamento, zoom e inversões horizontais.

2.2. Modelos

Os modelos, inicializados com pesos da ImageNet via *transfer learning*, foram treinados por 20 épocas. O processo iniciou-se com o treino das camadas de classificação (taxa de aprendizado de 0.001), seguido por um ajuste fino (*fine-tuning*) de toda a rede (taxa de 0.00001), usando a função de perda *categorical_crossentropy*.

Os modelos CNNs selecionados foram a **InceptionV3**, conhecida por seus "módulos inception" [Szegedy et al. 2016]; as **ResNet50** e **ResNet152**, que utilizam conexões de atalho para treinar redes profundas [He et al. 2016]; e a **DenseNet201**, que emprega conectividade densa para incentivar a reutilização de características [Huang et al. 2017].

2.3. Avaliação

Para avaliar o desempenho dos modelos, utilizou-se as métricas de acurácia, precisão, *recall*, *F1-Score* e *auc*, além da análise da curva roc. Essas métricas calculam seus valores a partir da matriz de confusão, que organiza as previsões em quatro categorias: *verdadeiros positivos* (TP), *falsos positivos* (FP), *falsos negativos* (FN) e *verdadeiros negativos* (TN).

As métricas são definidas conforme as Equações 1–4. A acurácia corresponde à proporção total de acertos; a precisão indica a proporção de positivos previstos que são realmente positivos; o *recall* representa a proporção de positivos reais corretamente identificados; e o *F1-Score* é a média harmônica entre precisão e *recall*. A curva roc mostra a relação entre a taxa de verdadeiros positivos e a de falsos positivos em diferentes limiares, enquanto a métrica *auc* quantifica a área sob essa curva, sendo valores próximos de 1 indicativos de alto desempenho discriminativo.

$$Acuracia = \frac{TP + TN}{TP + TN + FP + FN} \quad (1) \quad Recall = \frac{TP}{TP + FN} \quad (3)$$

$$Precisao = \frac{TP}{TP + FP} \quad (2) \quad F1-Score = \frac{2 * (Precisao * Recall)}{Precisao + Recall} \quad (4)$$

3. Resultados e Discussão

Os resultados da avaliação comparativa estão detalhados na Tabela 1. O DenseNet201 demonstrou o desempenho mais robusto, liderando não apenas em acurácia (95,93%), mas também em F1-Score (0.9491) e AUC (0.9962), métricas que indicam um balanço equilibrado entre precisão e recall e alta capacidade de discriminação entre as classes. O sucesso do modelo pode ser atribuído à sua arquitetura de conectividade densa, que promove a reutilização de características. Embora o InceptionV3 também tenha apresentado resultados competitivos, os modelos da família ResNet mostraram-se menos eficazes neste cenário, indicando que a profundidade da rede, por si só, não garantiu a melhor performance.

Tabela 1. Tabela Comparativa Final do Desempenho dos Modelos.

Modelo	Acurácia	Precisão	Recall	F1-Score	AUC	T° Treino (min)	T° Inferência (ms/img)
DenseNet201	0.9593	0.9497	0.9487	0.9491	0.9962	188.2	124.4
InceptionV3	0.9510	0.9411	0.9356	0.9381	0.9923	54.5	26.3
ResNet50	0.8684	0.8419	0.8460	0.8416	0.9734	85.5	52.6
ResNet152	0.8134	0.7637	0.7610	0.7614	0.9552	177.0	124.4

Ao contextualizar com o estado da arte, o desempenho do DenseNet201 é notável. Com uma acurácia de 95,93% e um F1-Score de 0.9491, o modelo se posiciona de forma altamente competitiva. Seus resultados são comparáveis a outras propostas recentes, como a EfficientNet-B1, que alcançou 95% tanto em acurácia quanto em F1-Score [Kumar et al. 2024], e a trabalhos que utilizaram a ResNet50, atingindo acuráncias de até 96,40% [Singh et al. 2024].

No que se refere à velocidade de inferência, aspecto crucial em cenários que demandam classificação em tempo quase real, o modelo InceptionV3 demonstra desempenho superior, configurando-se como a alternativa mais adequada para aplicações práticas em que a rapidez de resposta é determinante.

4. Conclusão

Este trabalho comparou quatro arquiteturas de CNN e validou a DenseNet201 como a mais eficaz na classificação de doenças foliares do milho, alcançando aproximadamente 96% de acurácia. Apesar de seu desempenho robusto, o modelo InceptionV3 mostrou-se mais adequado para aplicações em tempo real, por apresentar menor latência, *footprint* de memória reduzido e menor consumo energético, sendo ideal em cenários de triagem

rápida em campo. Propõe-se, assim, uma estratégia híbrida, em que modelos leves realizam a detecção inicial e arquiteturas mais complexas, como a DenseNet201, são aplicadas para revalidação offline.

A aplicação desta tecnologia oferece uma base para soluções acessíveis ao produtor rural brasileiro. A detecção precoce permite intervenções rápidas, reduzindo custos, otimizando o uso de defensivos e aumentando a rentabilidade. Essa abordagem contribui para o fortalecimento do agronegócio, reforçando o papel da IA como pilar para o futuro da agricultura de precisão no país.

Como trabalho futuro, recomenda-se avaliar essas arquiteturas em imagens de campo em tempo real, aproximando ainda mais a aplicação da realidade do produtor rural. Também será estudado formas de aumentar a precisão do modelo enquanto reduz seu tempo de inferência, possibilitando aplicações eficientes mesmo em tempo real.

Referências

Ghose, S. and Others (2020). Corn or Maize Leaf Disease Dataset. Acesso em: ago. 2025.

He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 770–778.

Huang, G., Liu, Z., Van Der Maaten, L., and Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 4700–4708.

Jasrotia, S., Yadav, J., Rajpal, N., Arora, M., and Chaudhary, J. (2023). Convolutional neural network based maize plant disease identification. *Procedia Computer Science*, 218:1712–1721.

Kumar, A., Nelson, L., and Venu, V. S. (2024). Efficientnet-b1 based maize plant leaf disease classification using deep learning. In *2024 2nd International Conference on Intelligent Data Communication Technologies and Internet of Things (IDCIoT)*, pages 1636–1642. IEEE.

Ma, Z., Wang, Y., Zhang, T., Wang, H., Jia, Y., Gao, R., and Su, Z. (2022). Maize leaf disease identification using deep transfer convolutional neural networks. *International Journal of Agricultural and Biological Engineering*, 15:187–195.

Mumuni, A. and Mumuni, F. (2022). Data augmentation: A comprehensive survey of modern approaches. *Array*, 16:100258.

Singh, G., Guleria, K., and Sharma, S. (2024). Leveraging transfer learning-based fine-tuned resnet50 model for maize leaf disease classification. In *2024 5th International Conference for Emerging Technology (INCET)*, pages 1–6. IEEE.

Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 2818–2826.