



## **DESENVOLVIMENTO DE SISTEMA MÓVEL PARA DIAGNÓSTICO DE DOENÇAS DO CAFEEIRO: um relato de pesquisa**

**Tiago F. MORAES<sup>1</sup>; Diego SAQUI<sup>2</sup>; Heber R. MOREIRA<sup>3</sup>; Caio E. DIAS<sup>4</sup>**

### **RESUMO**

Dada a importância econômica do café para o Brasil e sua vulnerabilidade a doenças, este relato de pesquisa apresenta um classificador automático para a sanidade de folhas de cafeiro. Utilizando o dataset BRACOL, foram comparadas quatro arquiteturas de aprendizado profundo, como *MobileNetV2* e *Vision Transformer* (ViT), que alcançaram acuráncias superiores a 95% na identificação das cinco classes de doenças e folhas saudáveis. Como principal contribuição prática, foi desenvolvido um aplicativo móvel multiplataforma com o modelo otimizado embarcado, permitindo o diagnóstico em tempo real e *offline*. O estudo valida a eficácia da visão computacional para o monitoramento fitossanitário e propõe, como trabalhos futuros, a expansão do classificador com novas patologias e a integração com dados climatológicos para aprimorar sua precisão.

#### **Palavras-chave:**

Inteligência Artificial; Visão Computacional; Diagnóstico Fitossanitário; Agricultura de Precisão.

### **1. INTRODUÇÃO**

O café é uma das *commodities* agrícolas mais importantes do Brasil, representando uma parte substancial das receitas de exportação do país. A produção e a industrialização do café contribuem diretamente para a economia nacional por meio do emprego, geração de valor agregado e desenvolvimento regional. Por exemplo, os estados de Minas Gerais, Espírito Santo e São Paulo estão entre os principais produtores de café, com Minas Gerais sendo responsável por mais da metade da produção de café do Brasil (BARBOSA; AGUILAR; MACIEL, 2021).

Apesar de suas contribuições econômicas significativas, o setor cafeiro no Brasil enfrenta vários desafios. Um dos maiores desafios é a vulnerabilidade da produção de café a fatores externos, como flutuações globais de preços, mudanças climáticas e pragas. Esses fatores podem ter um impacto prejudicial na lucratividade da produção de café e nos meios de subsistência dos cafeicultores (WATSON; ACHINELLI, 2008).

A adoção de modelos de aprendizado profundo, como *EfficientNetB0* e redes neurais convolucionais (CNNs), tem demonstrado resultados promissores na identificação de doenças em folhas de café, superando as abordagens tradicionais (SOMANNA; STYNES; MUNTEAN, 2024).

O objetivo deste trabalho é desenvolver um modelo de aprendizado de máquina para a

<sup>1</sup>Discente do Bacharelado em Ciência da Computação, IFSULDEMINAS – Campus Muzambinho. E-mail: tiago.fernandes@alunos.ifsuldeminas.edu.br.

<sup>2</sup>Orientador, Universidade Federal de Lavras (UFLA) - Campus São Sebastião do Paraíso. E-mail: diego.saqui@ufla.br.

<sup>3</sup>Orientador, IFSULDEMINAS – Campus Muzambinho. E-mail: heber.moreira@muz.ifsuldeminas.edu.br.

<sup>4</sup>Discente do Mestrado em Computação Aplicada, Instituto Nacional de Pesquisas Espaciais (INPE). E-mail: caioeduardo9700@gmail.com.

classificação de doenças e pragas em folhas de cafeeiro. A abordagem se baseia na análise de imagens foliares. Adicionalmente, propõe-se a construção de um aplicativo móvel que integra o modelo desenvolvido, visando validar sua aplicabilidade e facilitar o monitoramento fitossanitário em condições de campo.

## 2. FUNDAMENTAÇÃO TEÓRICA

A classificação de imagens por Redes Neurais Convolucionais (CNNs) baseia-se na detecção de padrões por meio de filtros em camadas, permitindo que o modelo aprenda representações visuais a partir de dados rotulados (AGGARWAL *et al.*, 2023). A escolha da arquitetura, como a *MobileNet*, representa um compromisso entre a complexidade do modelo e os requisitos de latência para aplicações em tempo real (HOWARD *et al.*, 2017). Para aferir a performance, utilizam-se métricas padrão como acurácia, precisão, recordação e pontuação F1 (*f1-score*), que quantificam a eficácia do modelo na tarefa de classificação (HANCHINAL, 2024).

## 3. MATERIAL E MÉTODOS

Este trabalho utilizou um acervo de imagens composto pelo conjunto de dados BRACOL (KROHLING; ESGARIO; VENTURA, 2019). O dataset consolidado abrange cinco classes representativas da sanidade de lavouras de café: Mancha de Phoma, Ferrugem, Cercosporiose, Bicho-Mineiro e Folhas Saudáveis. Para o treinamento e a avaliação do modelo proposto, este conjunto foi particionado em subconjuntos de treino, validação e teste.

Para a seleção da arquitetura final, avaliou-se o desempenho de quatro modelos de classificação de imagens: *MobileNetV2*, *ResNet50*, *Convolutional Random Forest* e *Vision Transformer* (ViT). O objetivo foi comparar a eficácia de cada um na tarefa proposta e analisar suas respectivas características de treinamento. Para avaliar o desempenho do modelo na classificação, foram utilizadas quatro métricas: acurácia, precisão, *recall* e *F1-score*.

## 4. RESULTADOS E DISCUSSÃO

Para capacitar os modelos na identificação de patologias, as quatro arquiteturas de rede neural foram treinadas com um acervo de 1747 imagens de café arábica via framework *TensorFlow*. O subsequente teste de performance, cujos resultados detalhados por métrica (acurácia, precisão, *recall* e *F1-score*) estão sumarizados na Tabela 1, confirmou a robustez da abordagem. Evidenciou-se uma alta performance geral, com os modelos de aprendizado profundo (*MobileNetV2*, *ResNet50* e ViT) ultrapassando a marca de 93% de *F1-score*, um patamar que demonstra grande confiabilidade para a tarefa de diagnóstico das doenças e pragas.

Tabela 1 – Métricas de desempenho dos modelos no conjunto de teste

Modelo	Acurácia	Precisão	Recall	F1-score	Latência (ms)
Convolutional Random Forest	0.56	0.56	0.56	0.55	86.7
MobileNetV2	0.96	0.96	0.96	0.96	3.9
ResNet50	0.98	0.98	0.98	0.98	6.5
Vision Transformer	0.94	0.94	0.93	0.93	18.19

Fonte: Autoria própria (2025)

A Figura 1 ilustra a interface do aplicativo móvel desenvolvido para materializar a pesquisa. Conforme apresentado na Figura 1a, o usuário submete a imagem da folha para análise. Após o processamento pelo modelo *TFLite* embarcado, o resultado é exibido em tempo real, como demonstrado na Figura 1b. Este resultado detalha a classificação da sanidade, o nível de confiança e uma sugestão de manejo, provendo um suporte à decisão instantâneo e *offline* para o produtor.

Figura 1 – Interface do aplicativo móvel: (a) tela de seleção de imagem e (b) tela de resultado do diagnóstico.



Fonte: Autoria própria (2025)

## 5. CONCLUSÃO

Os resultados obtidos demonstram que o classificador desenvolvido é uma ferramenta eficaz e robusta para a identificação automática das principais doenças foliares do cafeeiro, cumprindo com sucesso o objetivo deste trabalho. Como forma de dar continuidade e ampliar o impacto da solução, propõem-se duas frentes de pesquisa futuras. A primeira consiste em expandir a base de conhecimento do modelo, incluindo um espectro mais amplo de doenças e pragas. A segunda envolve a integração do classificador com dados climatológicos (como temperatura, umidade e

precipitação), visando à criação de um classificador mais versátil e preciso.

## AGRADECIMENTOS

Agradeço ao Instituto Federal de Educação, Ciência e Tecnologia do Sul de Minas Gerais (IFSULDEMINAS) – Campus Muzambinho, em especial ao Núcleo Institucional de Pesquisa e Extensão (NIPE) e ao Escritório Local de Inovação Tecnológica e Empreendedorismo (ELITE), pelo fomento e suporte financeiro que viabilizaram a execução deste projeto. Agradeço também, de forma especial, aos orientadores pela valiosa orientação e incentivo ao longo de toda a pesquisa.

## REFERÊNCIAS

AGGARWAL, S. *et al.* **Image Classification using Deep Learning: A Comparative Study of VGG-16, InceptionV3 and EfficientNet B7 Models.** In: INTERNATIONAL CONFERENCE ON ADVANCES IN COMPUTATION, INTELLIGENCE AND TECHNOLOGY (ICACIT), 2023, Lucknow. Anais [...]. Lucknow: IEEE, 2023. p. 1-6. Disponível em: <<https://doi.org/10.1109/icacite57410.2023.10183255>>. Acesso em: 20 jun. 2025.

BARBOSA, L. O. S.; AGUILAR, C.; MACIEL, L. L. **A participação de Minas Gerais e do Brasil na cadeia produtiva global do café.** Economia & Região, Londrina, v. 9, n. 1, p. 147-169, jan./abr. 2021. Disponível em: <<https://doi.org/10.5433/2317-627X.2021V9N1P147>>. Acesso em: 19 jun. 2025.

HANCHINAL, T. K. **An Analysis of Convolutional Neural Network for Image Classification.** International Journal for Research in Applied Science and Engineering Technology, v. 12, n. 5, p. 3374-3378, maio 2024. Disponível em: <<https://doi.org/10.22214/ijraset.2024.60719>>. Acesso em: 20 jun. 2025

HOWARD, A. *et al.* **MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications.** 2017. Preprint (arXiv:1704.04861). Disponível em: <<http://export.arxiv.org/pdf/1704.04861>>. Acesso em: 20 jun. 2025.

KROHLING, R. A.; ESGARIO, G. J. M.; VENTURA, J. A. **BRACOL - A Brazilian Arabica Coffee Leaf images dataset to identification and quantification of coffee diseases and pests.** Mendeley Data, 2019. v. 1. Disponível em: <<https://doi.org/10.17632/yy2k5y8mxg.1>>. Acesso em: 22 jun. 2025.

SOMANNA, H. P.; STYNES, P.; MUNTEAN, C. H. **A Deep Learning-Based Plant Disease Detection and Classification for Arabica Coffee Leaves.** In: FRED, A. *et al.* (Org.). Deep Learning Theory and Applications: DeLTA 2024. Cham: Springer, 2024. (Communications in Computer and Information Science, v. 2171). Disponível em: <[https://doi.org/10.1007/978-3-031-66694-0\\_2](https://doi.org/10.1007/978-3-031-66694-0_2)>. Acesso em: 19 jun. 2025.

WATSON, K.; ACHINELLI, M. L. **Context and contingency: the coffee crisis for conventional small-scale coffee farmers in Brazil.** The Geographical Journal, London, v. 174, n. 3, p. 223-234, set. 2008. Disponível em: <<https://doi.org/10.1111/j.1475-4959.2008.00277.x>>. Acesso em: 19 jun. 2025.