

Deep Learning Aplicado na Classificação de Doenças em Frutos do Cacaueiro

Gilberto N. Souza Jr.¹, Lariane J. B. Lima¹, Micaías De O. Silva¹, Edian F. F. de Los Santos², Emanuel M. Espailat², Denes S. Barros¹, Gustavo A. R. Alves¹, Daniel L. Souza³, Fabrício A. Araújo¹, Rommel T. J. Ramos⁴, Marcus B. Braga¹

¹Paragominas Campus – Universidade Federal Rural da Amazônia (UFRA) – PA-256, s/n, Nova Conquista – 68.627-451 – Paragominas – PA – Brazil.

²Universidad Tecnologica de Santiago (UTESA) – Av. Salvador Estrella Sadhalá, 75 – 51.000 – Santiago de los Caballeros – República Dominicana.

³Computer Science Department – Centro Universitário do Estado do Pará (CESUPA) Governador José Malcher Ave., 1963 – 66.060-230 – Belém – PA – Brazil.

⁴High Performance Computing Center, Laboratory of Simulation and Computational Biology. Universidade Federal do Pará. Augusto Correa Ave., 01. 66075-110 – Belém – PA – Brazil.

gilbertojr@ufra.edu.br, larianelima22@gmail.com,
micaiasdeoliveirasilva@gmail.com, efranco@utesa.edu,
emanuel.montero.e@gmail.com, denes.barros@ufra.edu.br,
gustavo.ruffeil@ufra.edu.br, daniel.leal.souza@gmail.com,
fabricio.araujo@ufra.edu.br, rommelramos@ufpa.br,
marcus.braga@ufra.edu.br

Abstract. *Cocoa cultivation in the Amazon is crucial for agricultural activity but faces challenges due to diseases that cause significant crop losses. To combat these diseases, artificial intelligence and deep learning emerge as promising solutions. This study proposes the use of convolutional neural networks to diagnose these diseases in cocoa fruits. Integrated into a mobile application, this system achieved 93% detection accuracy using computer vision techniques. This approach helps in early diagnosis and reducing production losses.*

Resumo. *O cultivo do cacau na Amazônia é crucial para a atividade agrícola, mas enfrenta desafios devido a doenças que causam perdas significativas nas lavouras. Para combater essas doenças, a inteligência artificial e a aprendizagem profunda surgem como soluções promissoras. Este estudo propõe o uso de redes neurais convolucionais para diagnosticar essas doenças em frutos de cacau. Integrado a um aplicativo móvel, esse sistema alcançou 93% de precisão na detecção por meio de técnicas de visão computacional. Essa abordagem auxilia no diagnóstico precoce e na redução de perdas de produção.*

1. Introdução

No século XVIII, o cultivo do cacau foi introduzido no sul do estado da Bahia, onde prosperou significativamente. No entanto, atualmente, o Pará é o maior produtor de cacau no Brasil, representando mais de 51% da produção nacional [Menezes 2020; Nunes S. M. et al. 2018]. O cultivo do cacau no Pará é incentivado por sua afinidade com a região amazônica, sua contribuição para a recuperação de áreas degradadas e sua relevância como matéria-prima. A cadeia produtiva envolve quase 26 mil produtores, principalmente da agricultura familiar, concentrados na região do Xingu, que representa 82% do total. O processo produtivo do cacau gera aproximadamente 64 mil empregos diretos e outros 255 mil indiretos, contribuindo com cerca de R\$ 1,1 bilhão [Menezes 2020].

No cultivo do cacau, pragas e doenças representam desafios significativos, afetando diretamente a qualidade e produtividade das lavouras e resultando em perdas consideráveis. Destacam-se a Vassoura de Bruxa (*Moniliophthora perniciosa*), que causa perdas superiores a 70% em áreas da Amazônia, e a Podridão Parda (*Phytophthora spp*), uma doença cosmopolita presente em todas as regiões produtoras do mundo. Para enfrentar esses desafios, a agrotecnologia e a agricultura de precisão surgiram como campos inovadores, utilizando análise intensiva de dados, sensores e técnicas como inteligência artificial, *Machine Learning* e *Deep Learning* [Kamilaris, A. e Prenafeta-Boldú 2018; Zhu et al. 2018].

O *Deep Learning*, subárea do *Machine Learning*, destaca-se pela sua aplicabilidade no processamento de imagens e análise de dados em diversos domínios. Assim, aliados à visão computacional, esses ramos do conhecimento apresentam potencial significativo para o diagnóstico de doenças em frutos de cacau, devido às suas características visuais distintas que facilitam a detecção por reconhecimento de imagem [Mitchell 1997; Zhu et al. 2018; Kamilaris e Prenafeta -Boldú 2018].

Stanley et al. (2018) utilizaram como banco de dados um total de 60 fotos de frutos de cacau onde foram classificados diversos níveis de infecção, utilizando técnicas de Aumento de Dados para treinar o modelo de IA, que apresentou uma precisão total de 84%. [Serrano 2020] utilizou um algoritmo de aprendizagem profunda YOLO para classificar imagens do cacau colombiano em saudável, podridão parda e vassoura de bruxa, com precisão de 60%. Barsi et al. (2019) utilizaram aprendizagem profunda para identificar características de 615 imagens de cacau. O aplicativo, baseado em aprendizado profundo, classifica os frutos como normais, doentes e com pragas e obteve 83,75% de acerto para frutos normais, 84,87% para frutos afetados por doenças e 80,80% para frutos afetados por pragas.

Com base nos potenciais benefícios da inteligência artificial aplicada no contexto da agricultura digital, este estudo teve como foco explorar técnicas computacionais para identificar as principais doenças do cacau na região amazônica, especificamente a Vassoura de Bruxa e a Podridão Parda, utilizando um modelo de aprendizagem profunda baseado em redes neurais convolucionais [Li, Zhang e Wang 2021; Naranjo et al. 2020] integradas a um aplicativo móvel capaz de classificar possíveis doenças por meio de imagens capturadas pelo usuário em tempo real [Susanti et al. 2023; Altalak et al. 2022].

2. Materiais e Métodos

As principais doenças que afetam as lavouras de cacau, como a Podridão Parda e a Vassoura de Bruxa, possuem características visuais distintas, o que permite sua detecção por meio de técnicas de reconhecimento de padrões de imagens, também conhecidas como visão computacional.

2.1. Base de Dados

Os dados primários utilizados neste estudo provêm de três fontes diferentes. A primeira consiste em imagens coletadas em fazendas na cidade de Davao, Filipinas, abrangendo as doenças Podridão Parda e Vassoura de Bruxa [Pagaduan 2021], onde foram selecionadas 1.148 imagens de frutas saudáveis, sendo 943 afetadas pela Podridão Negra e 87 com Vassoura de Bruxa. A segunda fonte de dados vem de [Serrano 2020], fornecida pela Universidade Autônoma de Bucaramanga, Colômbia, com um total de 211 imagens de Vassoura de Bruxa e 215 imagens de Podridão Parda. A terceira fonte de dados consiste em imagens coletadas em lavouras no estado brasileiro do Pará, nas cidades de Paragominas, Benevides e Tomé-Açu. Destas imagens foram selecionadas 77 de cacau Saudável, 57 de cacau com Vassoura de Bruxa e 25 imagens de doenças de Podridão Parda para teste e validação.

Para equilibrar o conjunto de dados, utilizou-se a técnica de aumento de dados nas imagens, especialmente para a classe minoritária, Vassoura de Bruxa. Além disso, a classe majoritária, “Saudável”, foi reduzida, considerando ângulos menos favoráveis. As imagens foram redimensionadas para 150 x 150 pixels, otimizando o tempo de processamento dos algoritmos. Ao final, o conjunto de dados foi dividido em três partes: 1.604 amostras para treinamento, 868 para validação e 1.054 para teste, totalizando 3.526 imagens entre originais e novas geradas a partir do conjunto inicial.

2.2 Modelo Proposto

Neste estudo, o processo de diagnóstico do cacau envolveu várias etapas. Primeiro, há a aquisição de imagens e a rotulagem dos dados, realizada por engenheiros agrônomos da Universidade Federal Rural da Amazônia. As imagens são classificadas em saudáveis, Vassoura de Bruxa e Podridão Parda. Em seguida, ocorre o pré-processamento dos dados, que são divididos em conjuntos de treinamento, validação e teste. O algoritmo de *Deep Learning* é treinado com hiperajuste dos parâmetros. O modelo mais preciso é implantado em um servidor de aplicação, onde é utilizado em conjunto com tecnologias backend para ser executado na web. Quando um usuário solicita a classificação de uma imagem de cacau através do aplicativo móvel, o servidor envia os resultados imediatamente, completando o processo de diagnóstico. Este processo pode é observado na Figura 1.

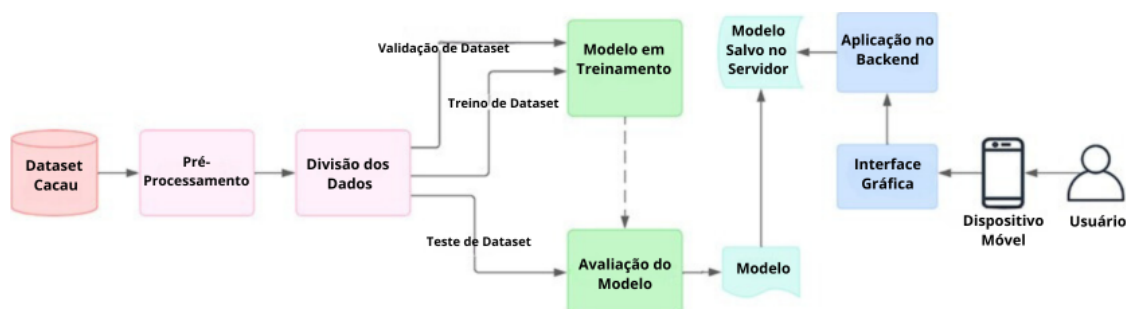


Figura 1. Pipeline do Modelo Proposto. (Fonte: Autores).

O ambiente de desenvolvimento incluiu *Python*, *Keras* e *TensorFlow*, além das bibliotecas *Matplotlib*, *Imageio*, *Numpy*, *Pandas* e *OpenCV*. O algoritmo foi construído no ambiente de desenvolvimento *Spyder* e executado em uma CPU *Intel Core i5* com 8 GB de RAM e 256 GB de SSD, no sistema operacional *Windows 11* de 64 bits. A arquitetura da CNN é composta por camadas convolucionais e de *pooling*, responsáveis pela extração de características das imagens (Figura 2). Na camada de entrada, uma imagem com dimensões de 150 x 150 pixels é apresentada à rede. Essa imagem passa por essas camadas e, em seguida, é achatada em uma matriz unidimensional. Por fim, a camada totalmente conectada, que consiste em um *Multilayer Perceptron* (MLP), realiza a classificação da imagem, apresentando o resultado na camada de saída.

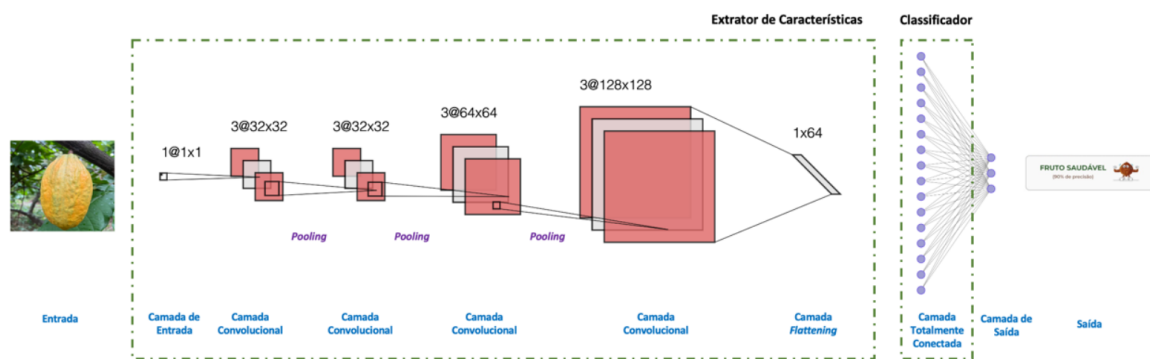


Figura 2. Arquitetura da CNN.

2.3 Desenvolvimento da Aplicação Móvel

Para facilitar o diagnóstico da doença em plantações de cacau, desenvolveu-se um aplicativo móvel que se comunica com a Rede Neural Convolucional (CNN) por meio de uma API. Esse aplicativo foi criado utilizando o *framework Flask*. Durante o desenvolvimento, adotou-se a metodologia de *Test Driven Development* (TDD), e o *wireframe* do projeto foi construído na plataforma *Figma*. O aplicativo foi codificado nativamente para *iOS* e *Android* usando o *framework React Native*, e a biblioteca *Expo Go* foi utilizada para testes e validação em tempo real durante o processo de desenvolvimento.

3. Resultados e Discussão

O modelo treinado apresentou um total de 504.163 parâmetros treináveis divididos entre as camadas de convolução, *pooling* e *flatten*. A Figura 3a mostra a curva de aprendizado do modelo ao longo das épocas de treinamento e teste. Neste contexto, a precisão alcançada foi de 93%. A Figura 3b mostra a matriz de confusão gerada com base no teste CNN (com 15% do total de dados, ou seja, aproximadamente 530 imagens).

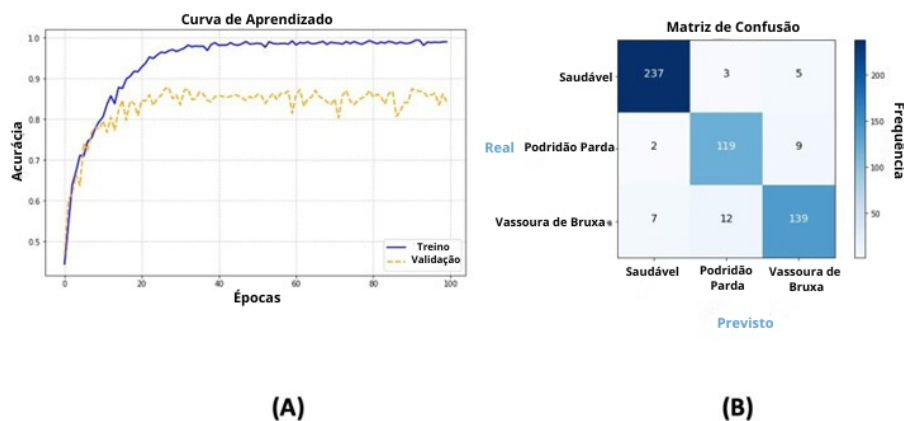


Figura 3. Curva de Aprendizagem (A) e Matriz de Confusão (B).

Analisando a matriz de confusão, pode-se inferir que o modelo teve mais dificuldade em classificar imagens de frutas com a doença Vassoura de Bruxa, que foi confundida 19 vezes entre as 158 testadas, indicando uma taxa de falso diagnóstico de aproximadamente 12%. Da mesma forma, as classes Saudável e Podridão Parda obtiveram uma taxa de erro aproximada de 3% e 8%, respectivamente.

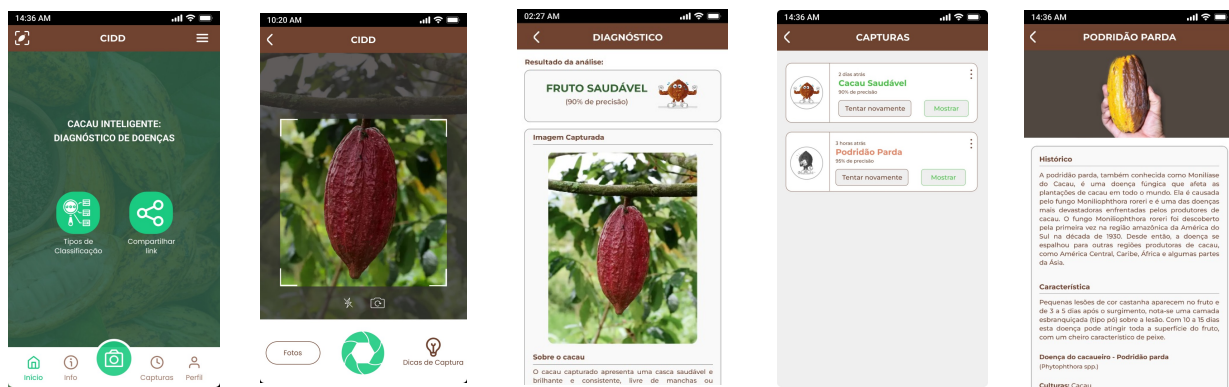


Figura 4. Telas principais do Aplicativo Móvel CIDD.

O aplicativo móvel desenvolvido, denominado CIDD - Cacau Inteligente: Diagnóstico de Doenças, tem como função inicial capturar a imagem do cacau utilizando a câmera do celular. Dicas sobre como tirar a melhor foto são fornecidas ao usuário para a melhor aquisição de imagem. O diagnóstico é realizado logo em seguida, classificando a imagem como "Fruto Saudável", "Podridão Parda" ou "Vassoura de Bruxa", gerando também uma análise gráfica da fruta classificada. É mostrada a porcentagem de acertos, que é a probabilidade de a fruta pertencer a uma das classes. Dependendo da classificação, um texto explicativo é fornecido ao usuário. Caso seja detectada alguma das doenças, é apresentado um texto com as principais causas e a forma adequada de gerir esta patologia. As imagens capturadas ficam salvas no aparelho e podem ser compartilhadas nas redes sociais. As principais telas de interface da aplicação desenvolvida são mostradas na Figura 4.

4. Considerações Finais

Neste estudo, a análise dos resultados do modelo inteligente destaca a importância da quantidade e qualidade dos dados de treinamento para a precisão do diagnóstico. O modelo ajustado demonstrou 93% de precisão geral e 92,8% de recall, evidenciando sua capacidade de identificar corretamente instâncias reais positivas.

A integração entre a inteligência artificial, a API e a interface do aplicativo móvel oferecem uma experiência eficaz e responsiva aos produtores de cacau. Essa arquitetura permite uma troca dinâmica de informações entre os componentes, garantindo interação fluida e respostas ágeis.

Em última análise, investir em tecnologias como essa não apenas protege os meios de subsistência dos agricultores, mas também assegura a sustentabilidade da indústria do cacau, preservando parte da identidade econômica e cultural do estado do Pará e do Brasil.

5. Agradecimentos

Os autores agradecem à Fundação da Amazônia de Amparo a Estudos e Pesquisa (FAPESPA) e ao CNPq pelo financiamento e concessão de bolsas de Iniciação Científica para a realização deste projeto, aprovado na Chamada 002/2021 FAPESPA/CNPq.

Referências

- Altalak, M., et al. (2022). Smart Agriculture Applications Using Deep Learning Technologies: A Survey. *Applied Sciences*.
- Kamilaris, A. e Prenafeta-Boldú, F. X. (2018), A review of the use of convolutional neural networks in agriculture. *The Journal of Agricultural Science*, 156, 312-322.
- Li, L., Zhang, S., & Wang, B. (2021). Plant Disease Detection and Classification by Deep Learning—A Review. *IEEE Access*, 9, 56683-56698.
- Menezes, C. (2020), Cacau paraense rompe fronteiras com qualidade e aumento da produção. Agência Pará. Governo do Pará. Disponível em: <https://agenciapara.com.br/noticia/20613/>.
- Mitchel, T. M. (1997), *Machine Learning*. McGraw-Hill International Editions. ISBN: 0070428077
- Naranjo Torres, J. A., et al. (2020). A Review of Convolutional Neural Network Applied to Fruit Image Processing. *Applied Sciences*.
- Nunes, S. M. et al. (2018), Cacau: produção, manejo e colheita. Brasília: Serviço Nacional de Aprendizagem Rural. Cartilha. Disponível em: <https://cnabrazil.org.br/busca?termo=cacau+produ%C3%A7%C3%A3o%2C+colheita%2C+armazenamento>. Acesso em: 20/03/2024.
- Pagaduan (2021). Cacao Diseases. Images of cacao with diseases. Disponível em: <https://www.kaggle.com/zaldyjr/cacao-diseases>.
- Senar. (2018). Cacau: produção, manejo e colheita / Serviço Nacional de Aprendizagem Rural – Brasília: SENAR, 2018. 145 p; il. 21 cm (Coleção Senar, 215). ISBN: 978-85-7664-197-1.

- Serrano, J. S. & Torres, C. A. (2020). Prototipo de aplicación móvil para la identificación de mazorcas de cacao enfermas haciendo uso de visión por computadora y aprendizaje de máquina. Disponible en: <http://hdl.handle.net/20.500.12749/13367>.
- Susanti, R., et al. (2023). The Use of Artificial Neural Networks in Agricultural Plants. *Andalus Journal of Electrical and Electronic Engineering Technology*.
- Zhu, N. Y. et al. (2018). Deep learning for smart agriculture: Concepts, tools, applications, and opportunities. *Int J Agric & Biol Eng*; 11(4): 32–44.