

Uso de deep learning para reconhecimento de doenças em bananicultura no município de Paragominas/PA

Use of deep learning for disease recognition in banana cultivation in the municipality of Paragominas/PA

Edson Magalhães da Costa¹  ; Maria Eliana da Silva Holanda²  ; Fabrício Almeida Araújo³  ; Gustavo Antonio Ruffeil Alves⁴  ; Carlos Douglas de Sousa Oliveira⁵  ; Gilberto Nerino de Souza Junior⁶  ; Marcus de Barros Braga^{7*} 

^{1,2,3,4,5,6,7} Universidade Federal Rural da Amazônia (UFRA), Campus Paragominas. *corresponding author: *marcus.braga@ufra.edu.br

Recebido 27/11/2023

Aceito 29/02/2024

Publicado: 06/03/2024

Resumo:

O estado do Pará vem se destacando desde a década de 1990 entre os cinco maiores produtores nacionais de banana. Na região norte, o estado paraense se destaca por ser o que mais produz banana. Em 2020, o município paraense de Paragominas produziu 416 toneladas da fruta, em área destinada à colheita de 32 ha, com rendimento médio de 13.000 kg/ha. Contudo, a ocorrência de muitas doenças nocivas aos plantios acaba interferindo negativamente na produção. O objetivo desta pesquisa é desenvolver uma solução computacional baseada na técnica de aprendizado de máquina, usando o processamento digital de imagens para realizar o diagnóstico automático de doenças da bananicultura. As imagens foram capturadas em solo paragominenses em pomares de bananas infectados pela Sigatoka Negra e pela Sigatoka Amarela. Aplicou-se a técnica conhecida como data augmentation, ou aumento de dados, para gerar automaticamente mais imagens das classes. Uma Rede Neural Convolutiva foi treinada e submetida aos dados de teste e validação. Os resultados mostraram que a Rede Neural Convolutiva foi uma estratégia robusta e facilmente implantável para detecção de doenças da bananeira. No passado recente, esperava trazer uma espécie de revolução na agricultura e hoje essas comprovações estão sendo constatadas com as inúmeras tecnologias disponíveis na atualidade. Mesmo sem um quantitativo tão grande de imagens para treinamento, o modelo obteve uma taxa de acerto de 86%, o que permite considerar uma ferramenta útil na detecção precoce de doenças na bananicultura, e essa pesquisa pode ser estendida ainda mais para desenvolver um aplicativo móvel totalmente automatizado para ajudar os produtores de banana locais, nacionais e internacionalmente.

Palavras-chave: Aprendizagem de máquina, plantas, banana, diagnóstico, visão computacional.

Abstract:

The state of Pará has stood out since the 1990s among the five largest national banana producers. In the northern region, the state of Pará stands out for being the one that produces the most bananas at the regional level. In 2020 Paragominas produced 416 tons of the fruit, in an area destined for harvesting and harvested area of 32 ha, with an average yield of 13,000 kg/ha. However, the occurrence of many harmful diseases to plantations ends up interfering negatively in production. The objective of this research is to develop a computational solution based on the machine learning technique, using digital image processing to perform the automatic diagnosis of banana diseases. The images were captured on Paragomin soil in banana orchards infected by Sigatoka Negra and Sigatoka Amarela. A technique known as data augmentation was applied to automatically generate more images of the classes. A Convolutional Neural Network was trained and submitted to test and validation data. The results showed that the Convolutional Neural Network was a robust and easily implantable strategy for detecting banana diseases. In the recent past, it hoped to bring about a kind of revolution in agriculture and today these evidences are being verified with the numerous technologies available today. This significant high success rate makes the model a useful early disease detection tool in banana farming, and this research can be extended further to develop a fully automated mobile application to help local, national and international banana farmers.

Keywords: machine learning, plants, banana, diagnosis, computer vision

1. Introdução

Em consonância com Cruvinel (2019), a bananeira é classificada como uma planta herbácea vivaz acaule da família *Musaceae* (*Musa* spp.). Proveniente do sudeste da Ásia, é uma das cultivares que mais se cultiva mundialmente, de modo especial nos países em desenvolvimento, principalmente no Brasil, o qual é o quarto maior produtor mundial.

O estado do Pará vem se destacando desde a década de 1990 entre os cinco maiores produtores nacionais de banana, colocando-se como maior produtor entre os anos de 1998 e 2000 (Costa *et al.*, 2017). Na região norte, o estado paraense se destaca por ser o que mais produz banana em nível regional. Esta é uma realidade também do município de Paragominas, que em 2020 produziu 416 toneladas da fruta, em área destinada à colheita e área colhida de 32 ha, com rendimento médio de 13.000 kg/ha (IBGE, 2021).

Contudo, a ocorrência de muitas doenças nocivas nos plantios de bananeiras acaba interferindo negativamente na produção. Dentre as doenças identificadas em solos paraenses estão a Sigatoka Amarela, Mal do Panamá, Moko e Sigatoka Negra. Os reflexos dessas doenças são sentidos pela rápida destruição da área foliar, reduzindo-se a capacidade fotossintética da planta e, conseqüentemente, a sua capacidade produtiva (Cruvinel, 2019).

A Sigatoka Amarela, também conhecida como “mal-desigatoca”, é causada pelo fungo *Mycosphaerella musicola*, que na fase assexuada corresponde ao fungo *Pseudocercospora musae* (Trindade *et al.*, 2002). O maior dano causado pela Sigatoka Amarela é a morte prematura das folhas, resultando em redução da produtividade e qualidade dos frutos (Figura 1).

Figura 1. (A) Amadurecimento precoce. (B) Primeiros sintomas. Fonte: os autores (2022).
Figure 1. (A) Early ripening. (B) First symptoms. Source: the authors (2022).



A Sigatoka Negra, a mais temível doença da bananeira, é causada por um fungo chamado *Mycosphaerella fijiensis* Morelet (estágio sexual) ou *Paracercospora fijiensis* (Morelet) Deighton (fase anamórfica), está se espalhando por todo o país (Trindade *et al.*, 2002). Ela é mais malévola que Sigatoka Amarela, e pode ocasionar perda da produção da cultura, em até 100%. Segundo Barros (2020), essa moléstia destrói as folhas, implicando na capacidade fotossintética, interferindo no crescimento e na produtividade da fruta (Figura 2).

Figura 2. Bananeiras afetadas pela Sigatoka Negra. Fonte: os autores (2022).
Figure 2. Banana plants affected by Black Sigatoka. Source: the authors (2022).



Surge então a necessidade de identificar o aparecimento de qualquer anormalidade nos cultivares nas fases iniciais do plantio para aplicar o corretivo apropriado garantindo o melhor rendimento na lavoura.

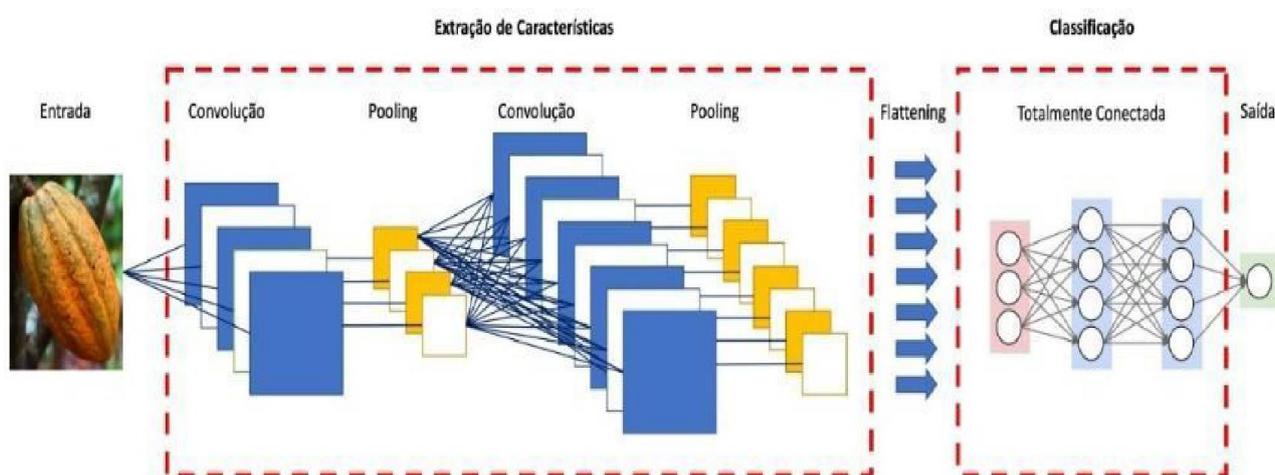
As técnicas de *Machine Learning* (ML) e *Deep Learning* (DL) já têm sido utilizadas com sucesso nas mais diversas áreas do conhecimento, incluindo as ciências agrárias, as quais na maioria das vezes são constituídas com algoritmos baseados em aprendizado de máquina para realizar diagnósticos precisos em campos de plantações.

O problema computacional básico consiste em fazer classificação de imagens e produzir como saída a probabilidade de pertencer a uma classe do conjunto (por exemplo, chegar a uma função que seja capaz de diferenciar imagens de bananas saudáveis e doentes). Assim quer-se definir uma função $f(x) = y$, onde x representa a imagem, e y a classe mais provável para x .

A técnica de Redes Neurais Convolucionais (*convolutional neural network* - CNN) é amplamente utilizada em problemas de classificação, reconhecimento e detecção em imagens. Na Figura 3, podemos visualizar um exemplo de sua estruturação.

Figura 3. Processamento digital de imagens através de redes neurais convolucionais. Fonte: adaptado de Holanda et al. (2021).

Figure 3. Digital image processing through convolutional neural networks. Source: adapted from Holanda et al. (2021).

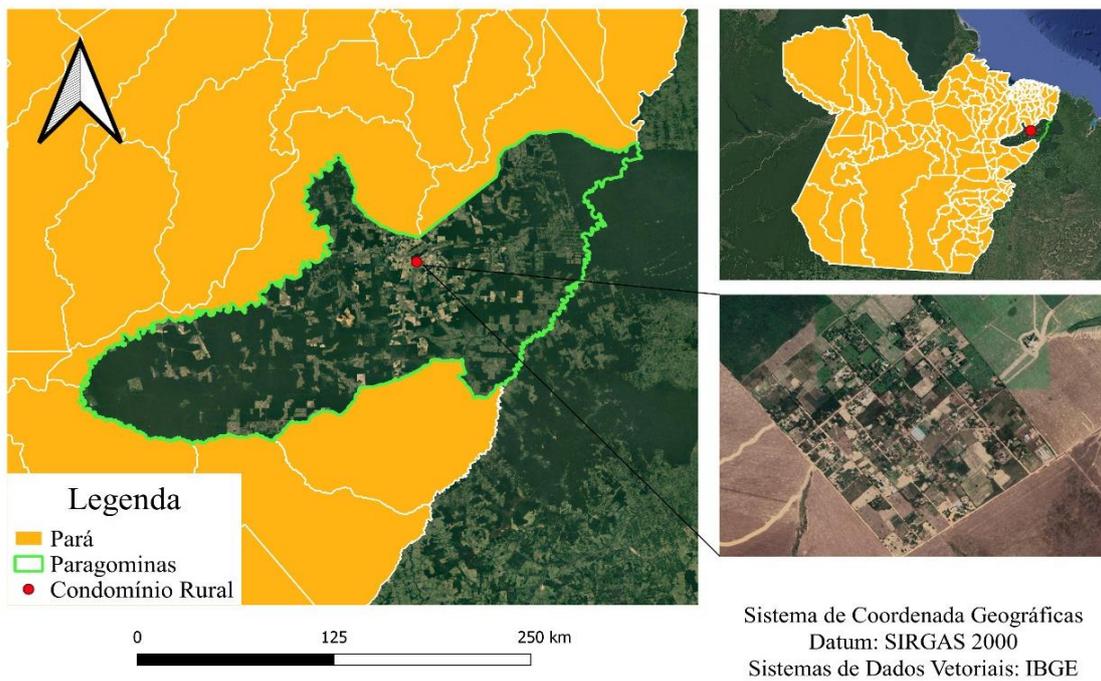


2. Material e Métodos

As imagens foram capturadas no Condomínio Rural, no município de Paragominas – PA (Figura 4), na região Sudeste do Pará e compreende uma área de aproximadamente 12 tarefas (1 tarefa pode ir de 2.500 m² a 3.000 m²), distribuídas em três propriedades locais, onde a banana é cultivada em consórcio com a cultura do cacau em dois dos cultivares (um de cada cultura). Enquanto que na terceira propriedade o agricultor tem um sistema agroflorestal, com a presença de diferentes culturas. As propriedades estão localizadas nas coordenadas geográficas: 3°00'52.0", S 47°24'32.9"W; 3°00'29.9"S, 47°24'56.6"W; 3°00'06.3"S 47°24'45.8"W, respectivamente situados na zona rural do município acima declarado.

Os valores de temperatura, umidade do ar e chuva, apontam o município como clima quente e úmido, do tipo Aw1 da classificação de *Köppen* (Clima tropical chuvoso, com expressivo período de estiagem) e B1wA'a', da classificação de *Thornthwaite* (Clima tropical úmido, com expressivo déficit hídrico) (IBGE, 2017). A área de estudo está localizada a 13km da sede municipal.

Figura 4. Mapa de localização do município de Paragominas – PA. Fonte: os autores (2022).
Figure 4. Location map of the municipality of Paragominas – PA. Source: the authors (2022).



Com a supervisão de um profissional qualificado na área de patologias da cultura em estudo, realizou-se a captura de 434 imagens por meio de celular. As imagens foram capturadas em solo paragominenses em pomares de bananas afetados pela Sigatoka Negra e pela Sigatoka Amarela. As fotografias foram agrupadas em três grupos: bananas saudáveis (135un), plantas com Sigatoka Negra (150un) e bananeiras com Sigatoka Amarela (149un). Na Figura 5 é possível visualizar parte da composição da base de dados.

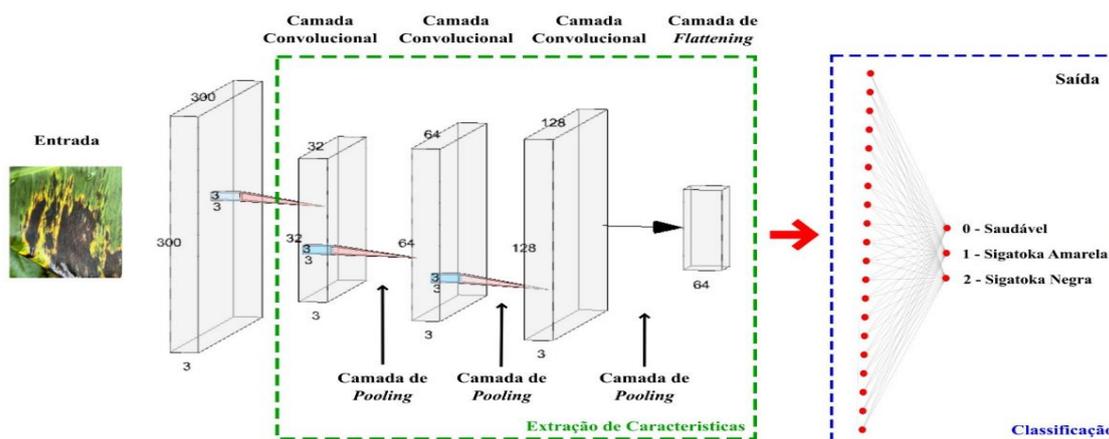
Figura 5. Parte da composição da base de dados. Fonte: os autores (2022).
Figure 5. Part of the database composition. Source: the authors (2022).



O modelo inteligente proposto neste projeto foi aplicado a um problema da grande área de Ciências Agrárias, conforme discutido previamente com os pesquisadores especialistas que participam da equipe, que é: Detectar os tipos de doenças em plantas a partir de imagens capturadas por celular. Os pesquisadores especialistas também são responsáveis por indicar a fonte das imagens que servirão de conjunto de treinamento, validação e teste para o sistema inteligente, em cada um dos problemas relacionados. O escopo do projeto foram culturas da banana, cultivares de suma importância das cadeias produtivas da região de Paragominas. Na Figura 6 é possível visualizar a arquitetura da CNN proposta.

Figura 6. Arquitetura da CNN proposta. Fonte: os autores (2022).

Figure 6. Proposed CNN architecture. Source: the authors (2022).



Conforme ilustrado na Figura 6, a arquitetura do modelo é composta por um neurônio na camada de entrada, que recebe uma imagem de 3 canais RGB de tamanho 300x300 pixels, seguidos de 3 camadas *convolutivas* sequenciais, intercaladas por camada de *pooling*. Por fim, há 2 camadas totalmente conectada, sendo que a última é relativa à camada de saída. A Tabela 1 apresenta uma descrição completa desse modelo.

Tabela 1. Configurações e Parâmetros Utilizados na CNN.

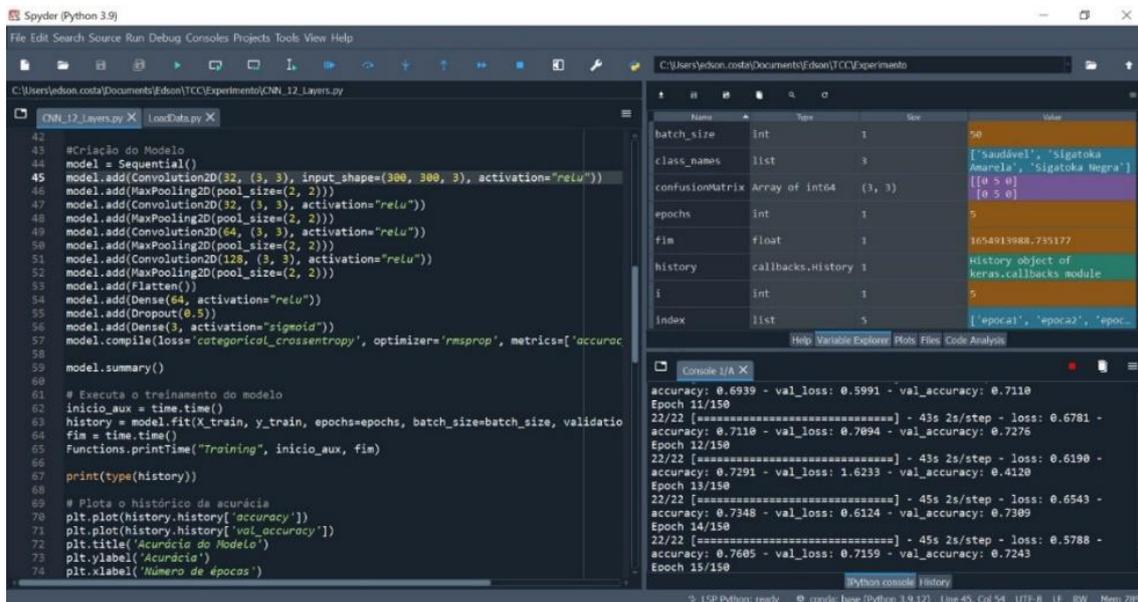
Table 1. Settings and Parameters Used in CNN.

Camada	Descrição
Camada de Entrada	1 neurônio RGB 3 canais, 300x300
Camada Convolutiva	Filtro Convolutiva, 32 neurônios 3x3 Função de Ativação ReLU
Camada de <i>Pooling</i>	2x2
Camada Convolutiva	Filtro Convolutiva, 64 neurônios 3x3 Função de Ativação ReLU
Camada de <i>Pooling</i>	2x2
Camada Convolutiva	Filtro Convolutiva, 128 neurônios 3x3 Função de Ativação ReLU
Camada de <i>Pooling</i>	2x2
Camada de <i>Flattening</i>	64
Camada Totalmente Conectada (<i>Fully-Connected Layer - MLP</i>)	64 neurônios ReLU Função de Ativação ReLU
Camada de <i>Dropout</i>	50% de chances
Camada de Saída	3 neurônios Função de Ativação Sigmoide

Neste trabalho foi usada a linguagem de programação *Python*, com a utilização da biblioteca *Keras*, o que simplifica bastante a construção, avaliação e validação de modelos de redes neurais e redes *convolucionais* e da biblioteca *TensorFlow*. Foi usado também o *Google Colab*, um serviço de nuvem gratuito hospedado pelo Google para incentivar a pesquisa de Aprendizado de Máquina e Inteligência Artificial, onde muitas vezes a barreira para o aprendizado e o sucesso é a exigência de muito poder computacional. Também foi usado a ambiente de desenvolvimento integrado *Spyder* para o desenvolvimento e teste do modelo inteligente (Figura 7).

Figura 7. Ambiente de desenvolvimento integrado Spyder. Fonte: os autores (2022).

Figure 7. Spyder integrated development environment. Source: the authors (2022).



3. Resultados e Discussão

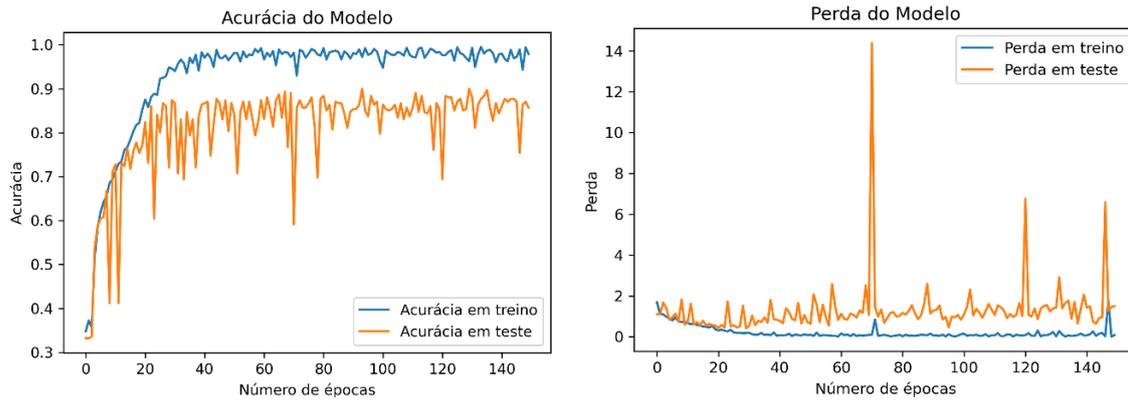
Como o banco de imagem possui uma quantidade relativamente pequena, o que pode interferir negativamente no resultado de treinamento do modelo em questão, aplicou-se a técnica conhecida como *data augmentation*, ou aumento de dados, para gerar automaticamente mais imagens das classes. Sendo assim, resultou-se em 500 imagens para cada classe. De posse das novas imagens geradas para as classes, a CNN foi treinada e submetida aos dados de teste e validação. A base de imagens foi dividida em dados de treinamento, teste e validação, sendo previamente divididos na seguinte proporção:

- Dados de Treino (70 %);
- Dados de Validação (20 %).
- Dados de Teste (10 %);

O modelo foi treinado com as configurações típicas de uma rede neural para esse tipo de problema de classificação acima mencionado. A curva de aprendizado e erro apresentados após o treinamento são mostradas na Figura 8.

Figura 8. Gráfico de curva de acurácia (esquerda) e perda (direita). Fonte: os autores (2022).

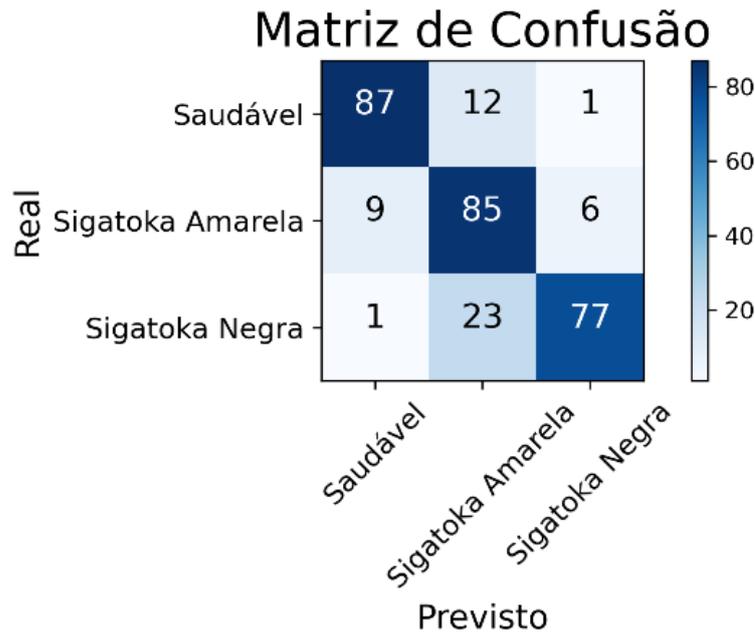
Figure 8. Accuracy (left) and loss (right) curve graph. Source: the authors (2022).



A CNN obteve uma acurácia de 0,86 (86%) e a função de perda chegou a 0,14 (14%). Importante destacar que para esse tipo de aplicação é esperado que o valor de acurácia seja o mais próximo possível de 1 e o valor de perda o mais próximo de 0. A partir da matriz de confusão ilustrada na Figura 9 podemos observar que o modelo treinado conseguiu classificar com boa performance entre as bananeiras saudáveis e afetadas, classificou erroneamente somente 13 imagens da classe saudável dentre 100 amostras.

Figura 9. Matriz de confusão mostrando os erros e acertos de classificação. Fonte: os autores (2022).

Figure 9. Confusion matrix showing classification errors and successes. Source: the authors (2022).



O resultado adquirido ainda não é o melhor resultado possível (86%), pois é necessária a aquisição de mais dados para chegar em um resultado satisfatório. Percebeu-se também que houve uma confusão da CNN quanto à classificação das imagens da Sigatoka Amarela e Sigatoka Negra. Contudo, segundo a literatura especializada, esta confusão também ocorre com os profissionais, pois as mazelas têm características visuais muitas parecidas e em alguns casos apenas uma minuciosa análise do um profissional especialista se conseguirá distinguir entre as duas doenças.

Ao realizar a avaliação da eficiência do modelo proposto comparando com outras abordagens (Tabela 2), percebe-se que o resultado obtido ficou abaixo da maioria dos resultados encontrados em

outras pesquisas com diferentes metodologias. Contudo a eficiência poderá ser melhorada com o aumento da base de dados para treinamento. Onde a aquisição própria dos dados de treinamentos é um dos maiores diferenciais do trabalho.

Tabela 2. Avaliação da eficiência do modelo proposto comparando com outras abordagens.
Table 2. Evaluation of the efficiency of the proposed model compared to other approaches.

Autores/ data	Modelo proposto	Resultados
WAGHMARE; KOKARE; DANDAWATE, (2016).	<i>Multiclass Support Vector Machine</i> como algoritmo de classificação em folhas de uva e identificação de doenças na cultura.	Tiveram 96,6% de precisão relatada, mas que pode ser melhorada se o número de amostras for aumentado.
ZHANG, et al. (2017).	Realizaram uma abordagem de reconhecimento de doenças do pepino que consiste em três procedimentos em pipeline: segmentação de imagens de folhas doentes por agrupamento K-means, extração de características de forma e cor de informações de lesões e classificação de imagens de folhas doentes usando representação esparsa (SR).	A abordagem proposta se mostra eficaz no reconhecimento de sete principais doenças do pepino com uma taxa de reconhecimento geral de 85,7%.
PANTAZI; MOSHOU; TAMOURIDOU (2019).	Padrões Binários Locais (LBPs) para extração de características e identificação de doenças em folhas de videira.	Alcançaram 95% de sucesso do total das 46 combinações testadas.
SELVARAJ, et al. (2020).	Classificações da banana baseadas em pixels e modelos de ML derivados de imagens de satélite <i>multinível (Sentinel 2, PlanetScope e WorldView-2)</i> e plataformas UAV (<i>MicaSense RedEdge</i>).	Obteve-se 97% de precisão geral.
LIMA, et al. (2021).	Técnicas de Redes Neurais Convolucionais (CNN) para classificação de imagens e detecção de doenças da cultura do milho.	Indicaram precisão média acima de 94,5%.

É possível observar que os estudos que envolvem modelos de aprendizado profundo e técnicas de aprendizado de transferência no diagnóstico de doenças de culturas estão em ascensão e que estão sendo melhorados com o passar dos tempos (ZHANG *et al.*, 2017; WAGHMARE *et al.*, 2016; SELVARAJ *et al.*, 2020; SANGA *et al.*, 2020). Além disso, diversas métricas de desempenho são utilizadas para a avaliação dessas arquiteturas/técnicas. Muitas arquiteturas *Deep Learning* desenvolvidas/modificadas são implementadas juntamente com várias técnicas de visualização para detectar e classificar os sintomas de doenças de plantas e aplicadas com sucesso.

As aplicações do tipo *mobile*, com capacidade de operação *off-line* ganham destaque entre as aplicações emergentes para a detecção precoce de doenças de diversas culturas. Em pesquisa realizada por Sanga *et al.* (2020), os autores avaliaram o desempenho da ferramenta *FUSI Scanner (Fusarium Sigatoka)*, para detectar a presença de duas das principais doenças fúngicas da bananeira: a Sigatoka negra e o Mal do Panamá.

Em ambos os testes, conforme a literatura recomenda, os resultados, para terem o nível aceitável de confiança, devem ser pelo menos de 70%, caso contrário, o aplicativo deve solicitar uma imagem mais nítida da folha capturada.

A agricultura cumpre importante papel na economia mundial, porém tem vários fatores limitantes como a presença de pragas. Observa-se que as plantas são uma importante fonte de energia para o ser humano, assim como para outros animais. É então importante identificar as folhas infectadas que são afetadas pela doença; isso será de grande ajuda para os agricultores protegê-lo da semeadura até o processo de colheita que pode refletir na redução das perdas econômicas.

O trabalho manual de identificação de doenças se torna cansativo e, por vezes, falho, portanto, a identificação automática de doenças e seu diagnóstico precoce será uma ferramenta adicional para o rendimento agrícola e também ajudará a maximizar a produção da cultura. Em muitos experimentos e avaliações, processos de segmentação, extração de características e métodos de classificação estão sendo feitos para diagnóstico rápido em doenças foliares selecionadas.

No estudo desenvolvido por Jogekar & Tiwari (2021), foi discutida uma análise comparativa entre os desempenhos de abordagens de aprendizagem profunda para identificação e diagnóstico de várias doenças em folhas de plantas com a ajuda de diferentes padrões de imagens. Assim, os autores ajudaram os agricultores a identificar e diagnosticar a doença em folhas de bananeira usando uma rede neural convolucional profunda que pode ser tratada no estágio inicial.

As doenças de plantas afetam o crescimento de suas respectivas espécies e também interferem na produção de frutos de qualidade, portanto, sua identificação precoce é muito importante. Muitos modelos de *Machine Learning* têm sido empregados para a detecção e classificação de doenças de plantas, mas, após os avanços em um subconjunto de ML, ou seja, *Deep Learning*, essa área de pesquisa parece ter um grande potencial em termos de precisão aumentada. Que pode ser comprovada no desenvolvimento de Holanda *et al.* (2021).

4. Conclusão

Observou-se que o ajuste fino das redes pré-treinadas obteve melhores resultados de classificação do que o treinamento do zero. Entre as frutas colhidas, a banana é uma das culturas mais significativas no comércio nacional e internacional. Atualmente, as doenças da folha de bananeira são os fatores mais significativos em relação aos produtos agrícolas. Essas doenças resultam em um grave declínio na quantidade e qualidade dos alimentos agrícolas. Além disso, o reconhecimento precoce e a classificação dessas doenças da folha de bananeira são muito necessários.

Os resultados mostraram que a CNN foi uma estratégia robusta e facilmente implantável para detecção de doenças da bananeira. Usando um modelo supervisionado de classificação de doenças, conseguiu-se realizar o aprendizado profundo e produzir uma rede neural artificial profunda capaz de fazer previsões precisas. Essa alta taxa de sucesso significativa torna o modelo uma ferramenta útil de detecção precoce de doenças na bananicultura, e essa pesquisa pode ser estendida ainda mais para desenvolver um aplicativo móvel totalmente automatizado para ajudar os produtores de banana locais, nacionais e internacionalmente, com foco principalmente na agricultura familiar onde é precário de recursos e conhecimentos técnicos de manejo de doenças em suas propriedades.

O estudo mostrou que a detecção precoce em tempo real é muito importante para enfrentar o problema de doenças da bananeira e melhorar os rendimentos deste tipo de a cultura, que é normalmente afetada por doenças. O modelo de solução aplicado, com o uso de técnicas de aprendizado de máquina e telefones celulares, se mostrou adequado para o trato dessas doenças que podem ser facilmente detectadas visualmente, permitindo um manejo de maneira adequada.

Referências

BARROS, V.G.L.R. **Avaliação da incidência e severidade da Sigatoka-amarela em cultivares de bananas sob doses de água e nutrientes**. Brasília: Trabalho de Conclusão de Curso - Universidade de Brasília 2020. Disponível em: <https://bdm.unb.br/handle/10483/27747>. Acesso em: 22 de maio de 2022.

COSTA, M. R. T. R.; HOMMA, A. K. O.; REBELLO, F. K.; SOUZA FILHO, A. P. S.; COSTA, W. B.; FERNANDES, G. L. C. **Atividade agropecuária no estado do Pará**. Embrapa Amazônia Oriental: Belém, 2017. p. 174 (Embrapa Amazônia Oriental. Documentos, 432). ISSN: 1983-0513.

CRUVINEL, P. E. **Gerenciamento de risco decorrente de doenças fúngicas em cultura da banana baseado em automação e aprendizado de máquinas**. Campinas: Embrapa Instrumentação-Resumo em anais de congresso. Congresso brasileiro de engenharia agrícola, 2019. Disponível em: <https://www.alice.cnptia.embrapa.br/alice/handle/doc/1114577>. Acesso em: 20 de maio de 2022.

HOLANDA, M. E. S.; COSTA, E.M.; OLIVEIRA, D. K. L. O.; LIMA, P. V. C.; SANTO, E. T. E.; RAMOS, L. H. D.; SOARES, L. H. M.; RAMOS, R. C.; COSTA, J. S.; SANTOS, I. M., SILVA, J. M. L.; JÚNIOR, G. N. S.; BRAGA, M. B. **Aplicação de aprendizado de máquina profundo para detecção por imagens de doenças em frutos do cacauzeiro**. International Journal of Development Research, 2021. v. 11, n. 05, p. 47378-47384. DOI: <https://doi.org/10.37118/ijdr.22009.05.2021>.

IBGE. Paragominas: Instituto brasileiro de geografia e estatística, 2017. Disponível em: <http://www.cidades.ibge.gov.br/painel/historico.php?codmun=150550>. Acesso em: 26 de maio de 2022.

IBGE, **Produção Agrícola Municipal 2020**. Rio de Janeiro: Instituto brasileiro de geografia e estatística, 2021. Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9117-producao-agricola-municipal-culturas-temporarias-e-permanentes.html>. Acesso em: 26 de maio de 2022.

JOGEKAR, R. N; TIWARI, N. **A review of deep learning techniques for identification and diagnosis of plant leaf disease**. Smart Trends in Computing and Communications: Proceedings of SmartCom 2020, p. 435-441, 2021. DOI: https://doi.org/10.1007/978-981-15-5224-3_43.

LIMA, P.; COSTA, E.; HOLANDA, M.; OLIVEIRA, D.; SANTO, E.; RAMOS, L.; SOARES, L.; SANTOS, I.; ARAUJO, F.; SILVA, J.; SOUZA JUNIOR, G.; BRAGA, M. **Use of Convolutional Neural Networks in the Diagnosis of Corn Diseases**. Sociedade Brasileira de Inteligência Computacional, 2021. Disponível em: https://sbic.org.br/wp-content/uploads/2021/09/pdf/CBIC_2021_paper_27.pdf. Acesso em: 26 de maio de 2022. DOI: 10.21528/CBIC2021-27.

PANTAZI, X. E.; MOSHOU, D.; TAMOURIDOU, A. A. **Automated leaf disease detection in different crop species through image features analysis and One Class Classifiers**. Computers and electronics in agriculture, v. 156, p. 96-104, 2019. DOI: <https://doi.org/10.1016/j.compag.2018.11.005>.

SANGA, S.; MERO, V.; MACHUVE, D.; MWANGANDA, D. **Mobile-Based Deep Learning Models for Banana Diseases Detection**. arXiv preprint arXiv:2004.03718, 2020. DOI: <https://doi.org/10.48550/arXiv.2004.03718>.

SELVARAJ, M. G.; VERGARA, A.; MONTENEGRO, F.; RUIZ, H. A.; SAFARI N.; RAYMAEKERS, D.; OCIMATI, W.; NTAMWIRA, J.; TITS, L.; Omondi, A. B.; BLOMME, G. **Detection of banana plants and their major diseases through aerial images and machine learning methods: A case study in DR Congo and Republic of Benin**. ISPRS Journal of Photogrammetry and Remote Sensing, v. 169, p. 110-124, 2020. ISSN: 0924-2716. DOI: <https://doi.org/10.1016/j.isprsjprs.2020.08.025>.

TRINDADE, D. R.; TABOSA, S. A.; LEITE, M. A. N.; POLTRONIERI, L. S.; DUARTE, M. L. R. **Doenças da bananeira no estado do Pará**. Belém: Embrapa Amazônia oriental - circular técnica, 2002. ISSN: 1517-211.

WAGHMARE, H.; KOKARE, R.; DANDAWATE, Y. **Detection and classification of diseases of grape plant using opposite colour local binary pattern feature and machine learning for automated decision support system.** Noida: 3rd International Conference on Signal Processing and Integrated Networks - IEEE, p. 513-518, 2016. DOI: 10.1109/SPIN.2016.7566749.

ZHANG, S.; WU, X.; YOU, Z.; ZHANG, L. **Leaf image based cucumber disease recognition using sparse representation classification.** Computers and electronics in agriculture, v. 134, p. 135-141, 2017. ISSN: 0168-1699, DOI: <https://doi.org/10.1016/j.compag.2017.01.014>.

Author contribution:

Edson Magalhães da Costa: Conceituação, Curadoria de Dados, Investigação, Metodologia, Análise Formal, Software, Visualização e Escrita – Primeira Redação.

Maria Eliana da Silva Holanda: Conceituação, Curadoria de Dados, Investigação, Metodologia, Análise Formal, Visualização e Escrita – Primeira Redação.

Fabício Almeida Araújo: Validação, Software e Revisão.

Gustavo Antonio Ruffeil Alves: Curadoria de Dados, Investigação e Validação.

Carlos Douglas de Sousa Oliveira: Validação e Escrita – Revisão e Edição.

Gilberto Nerino de Souza Junior: Administração do Projeto, Validação, Software e Escrita – Revisão e Edição.

Marcus de Barros Braga: Supervisão, Administração do Projeto e Recursos, Obtenção de Financiamento e Escrita – Revisão e Edição.

Acknowledgment

Agradecemos a todos profissionais de Agronomia que nos auxiliaram na identificação das doenças da bananeira e na escolha do ambiente para construção do banco de imagem.

Aos produtores rurais de Paragominas que cederam suas propriedades para fazermos a composição do banco de imagens com doenças de bananeiras.

Agradecemos também ao Grupo de Pesquisa Núcleo de Pesquisas em Computação Aplicada por todas as experiências vivenciadas e trabalhos acadêmicos produzidos, os quais serviram como base para a construção desta pesquisa.

Financing Sources

Essa pesquisa foi financiada pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq e ao Ministério da Ciência, Tecnologia e Inovações - MCTI, por meio da Secretaria de Empreendedorismo e Inovação – SEMPI. Este trabalho contou com a concessão de bolsas da Chamada CNPq/MCTI/SEMPI Nº 14/2021.

Conflict of Interest

Os autores declaram não haver conflito de interesse.

Associate Editor

Luciana da Silva Borges

ORIGINAL ARTICLE

