

**UM MODELO BASEADO EM TRANSFERÊNCIA DE APRENDIZADO PROFUNDO PARA
DETECÇÃO DO MAL-DO-PANAMÁ**

A DEEP LEARNING TRANSFER-BASED MODEL FOR PANAMA DISEASE DETECTION

**UN MODELO BASADO EN TRANSFERENCIA DE APRENDIZAJE PROFUNDO PARA LA
DETECCIÓN DEL MAL DE PANAMÁ**



10.56238/revgeov16n4-073

Lucas Ledo de Oliveira

Graduado em Gestão da Tecnologia da Informação
Instituição: Instituto Federal Baiano (IFBAIANO)
E-mail: gti.lucasledo@gmail.com

Tiago do Carmo Nogueira

Doutor em Engenharia Elétrica e de Computação
Instituição: Universidade Federal de Goiás (UFG), Instituto Federal Baiano (IFBAIANO)
E-mail: tiago.nogueira@ifbaiano.edu.br

Caio Henrique Rodrigues Carvalho

Mestre em Engenharia Elétrica
Instituição: Universidade Federal do Piauí (UFPI), Instituto Federal Baiano (IFBAIANO)
E-mail: caio.carvalho@ifbaiano.edu.br

Danyelete de Oliveira Santana

Mestranda em Ciência da Computação
Instituição: Universidade Estadual de Feira de Santana (UEFS), Instituto Federal Baiano
(IFBAIANO)
E-mail: danyelete.santana@ifbaiano.edu.br

Luciano Mesquita Silva

Mestrando em Produção Vegetal no Semiárido
Instituição: Instituto Federal Baiano (IFBAIANO)
E-mail: luciano.silva@ifbaiano.edu.br

Welison de Brito dos Santos Batista

Graduado em Análise e Desenvolvimento de Sistemas
Instituição: Instituto Federal Baiano (IFBAIANO)
E-mail: welison.batista@ifbaiano.edu.br

Matheus Rudolfo Diedrich Ullmann

Doutorando em Engenharia Elétrica e de Computação
Instituição: Universidade Federal de Goiás (UFG), Instituto Federal da Bahia (IFBA)
E-mail: matheusullmann@ifba.edu.br



RESUMO

Abordagens de aprendizado profundo são aplicáveis ao processo produtivo da banana (*Musa spp.*). A fitopatologia mal-do-Panamá pode causar perdas de até 100% na cultura. Como mecanismo de detecção, técnicas de extração de características em imagens podem ser aplicadas pela Transferência de Aprendizado Profundo (DTL). Este trabalho visa aplicar e avaliar um algoritmo DTL capaz de classificar tal doença a partir de 102 imagens de folhas da bananeira doentes e 264 saudáveis. Foram testados seis modelos neurais pré-treinados do estado da arte e avaliados com base em: acurácia (ACC), f1-score (F1), área sob a curva (AUC) e erro médio quadrático (MSE). Todos obtiveram acurácia acima de 98%. A detecção ágil deve auxiliar o bananicultor à tomada de decisão hábil.

Palavras-chave: Aprendizado Profundo. Detecção. Mal-do-panamá.

ABSTRACT

Deep learning approaches are applicable to the banana (*Musa spp.*) production process. The Panama disease phytopathology can cause losses of up to 100% in the crop. As a detection mechanism, image feature extraction techniques can be applied through Deep Transfer Learning (DTL). This work aims to apply and evaluate a DTL algorithm capable of classifying this disease using 102 images of diseased banana leaves and 264 healthy ones. Six pre-trained state-of-the-art neural models were tested and evaluated based on: accuracy (ACC), f1-score (F1), area under the curve (AUC), and mean squared error (MSE). All models achieved accuracy above 98%. The agile detection should assist banana farmers in making timely decisions.

Keywords: Deep Learning. Detection. Panama Disease.

RESUMEN

Los enfoques de aprendizaje profundo son aplicables al proceso productivo del banano (*Musa spp.*). La fitopatología conocida como Mal de Panamá puede causar pérdidas de hasta el 100% en el cultivo. Como mecanismo de detección, se pueden aplicar técnicas de extracción de características en imágenes mediante Transferencia de Aprendizaje Profundo (DTL, por sus siglas en inglés). Este trabajo tiene como objetivo aplicar y evaluar un algoritmo de DTL capaz de clasificar dicha enfermedad a partir de 102 imágenes de hojas de banano enfermas y 264 sanas. Se probaron seis modelos neuronales preentrenados de última generación y se evaluaron según los siguientes criterios: exactitud (ACC), puntuación F1 (F1), área bajo la curva (AUC) y error cuadrático medio (MSE). Todos obtuvieron una precisión superior al 98%. La detección ágil debe ayudar al productor bananero en la toma de decisiones eficaces.

Palabras clave: Aprendizaje Profundo. Detección. Mal de Panamá.



1 INTRODUÇÃO

Os recentes avanços em Inteligência Artificial (IA) têm impactado de maneira positiva o desenvolvimento das ciências agrárias. De acordo com Almeyda e Ipanaque (2022), as abordagens de aprendizado profundo (do inglês deep learning - DL) têm sido amplamente utilizadas para a solução de problemas na cadeia produtiva da banana. Desse modo, uma das técnicas aplicáveis ao campo para o auxílio das práticas agrícolas são as redes neurais convolucionais (do inglês convolutional neural network - CNNs) (BEGUM et al., 2020; EUNICE et al., 2022; RAGHAVENDRA et al., 2022; TEJASWINI et al., 2022).

A banana (*Musa spp.*) é uma fruta cultivada em países de clima tropical, sendo fonte de alimento e de renda para milhões de pessoas. No cenário mundial, o Brasil está posicionado como o 2º (segundo) maior produtor, além de contar com ampla difusão da bananicultura no território, principalmente no Nordeste brasileiro. Em termos econômicos, a banana é cultivada por pequenos, médios e grandes produtores – a agricultura familiar é responsável por 60% da produção. Ainda tem destaque como a 2ª (segunda) fruta mais relevante em: área colhida, quantidade produzida, valor da produção e consumo (EMBRAPA, 2022).

O acometimento de pragas e doenças na cultura da banana é um problema frequente e impactante. Uma das fitopatologias de maior importância é o mal-do-Panamá, também nomeado de murcha de *Fusarium* ou fusariose. Esta é uma doença causada pelo fungo *Fusarium oxysporum* f. sp. *cubense*, transmitida pelo solo, que danifica o corpo da bananeira através das raízes. Entre os sintomas, estão o amarelecimento e murcha das folhas, que ficam penduradas ao redor do pseudocaule. Como consequência, há redução da qualidade dos frutos e da produtividade, podendo causar perdas de até 100% da colheita (ATHIRAJA; VIJAYAKUMAR, 2021; MUHAMMAD; ZAWAWI; JEMALI, 2023; SANGEETHA et al., 2023).

A facilidade de disseminação e o potencial destrutivo da fusariose são um fator que garante forte presença da doença e grande preocupação entre agricultores nas regiões produtoras de banana no Brasil. Em Bom Jesus da Lapa, Bahia, lócus desta pesquisa, o Projeto Público de Irrigação (PPI) Formoso - em que, no ano de 2021, 90% da área plantada correspondia à bananicultura (CODEVASF, 2022) - coloca o referido município entre os maiores produtores de banana do País. Pensando nisto, manifesta-se a necessidade de uma ferramenta simples e confiável para detecção desta doença: um modelo de classificação baseado em aprendizado profundo, CNNs e processamento de imagens.

Para realizar a detecção do mal-do-Panamá, técnicas de extração de características em imagens foram aplicadas a partir da criação e do treinamento de modelos de CNNs aliados ao aprendizado de transferência (do inglês transfer learning - TL). O aprendizado profundo (DL) é tido como a tecnologia de visão computacional mais avançada para classificação de imagens. TL é uma abordagem de reutilização de uma rede pré-treinada em uma nova tarefa, isto é, explora-se o conhecimento adquirido



em uma tarefa anterior para melhorar a generalização sobre outra, sendo possível treinar a rede com quantidade reduzida de dados e alta precisão (GAUTAM et al., 2022). A Transferência de Aprendizado Profundo (do inglês deep transfer learning (DTL) é uma metodologia que tem ganhado enorme popularidade entre as técnicas disponíveis devido ao alto desempenho na identificação de doenças foliares de plantas (DHAKA et al., 2021).

Este trabalho visa aplicar um algoritmo de aprendizado profundo capaz de classificar, com satisfatório grau de precisão, a presença da murcha de *Fusarium* na folha da bananeira. O sistema recebe as imagens como entrada, processa e as classifica, de modo a fornecer conhecimento útil e confiável a produtores rurais. Foram selecionados e testados 06 (seis) modelos neurais pré-treinados do estado da arte, avaliados a partir de métricas abordadas em trabalhos correlatos, a saber: avaliação de acurácia (ACC), f1-score (F1), área sob a curva (AUC) e erro médio quadrático (MSE).

2 TRABALHOS RELACIONADOS

Nesta seção são apresentados estudos recentes que abordam a detecção de doenças foliares de plantas com base em CNNs. Consta-se que as abordagens de aprendizado profundo têm sido amplamente utilizadas para a solução de problemas na cadeia produtiva da banana (ALMEYDA; IPANAQUE, 2022).

Modelos CNN resolvem os problemas dos métodos tradicionais de detecção e classificação de objetos (TUGRUL; ELFATIMI; ERYIGIT, 2022). E, desde que haja dados suficientes para treinamento, as técnicas de aprendizado profundo permitem o reconhecimento de doenças foliares de plantas com alta precisão (LI; ZHANG; WANG, 2021). Em folhas de bananeira, a identificação e classificação de doenças são mais precisas com a utilização de técnicas de processamento de imagem. Essas tecnologias otimizam os recursos necessários para o diagnóstico (KRISHNAN et al., 2022).

Em uma perspectiva inovadora, Khamparia et al. (2020) estabelece uma técnica para detecção de doenças em folhas de planta a partir de uma abordagem híbrida. Baseada em aprendizado profundo e na codificação de auto-codificadores, resulta em uma rede de codificadores convolucionais. Os resultados apontam 97.50% de acerto com um filtro de convolução 2x2 em 100 épocas e 100% de acerto com um filtro 3x3. As taxas de acertos mostraram-se superiores às técnicas convencionais.

Paralelamente, Yadhav et al. (2020) trazem um modelo de CNN implementado no sistema TensorFlow para classificação de doenças de plantas. Com base nos resultados, é possível afirmar que o modelo proposto tem precisão de 95%. Os otimizadores Adam e Adamax mostram melhor otimização se comparados a outras funções. Também foi utilizado algoritmo de agrupamento K-means no MATLAB para calcular a porcentagem de área acometida pela doença.

Em vista do recorrido, pode-se focalizar a pesquisa sobre a detecção de doenças na cultura da banana. De acordo com Nandhini et al. (2021), construir, treinar e implantar um modelo de aprendizado



profundo rápido e flexível para produção em larga escala pode ajudar a gerenciar o cultivo de bananeira. Isto porque é uma técnica capaz de prever doenças, ervas daninhas e pragas.

A detecção de doenças da bananeira pode ser feita com maior precisão a partir de técnicas de processamento de imagem. A técnica proposta por Mahendran e Seetharaman (2022) pode ser utilizada para determinar doenças. O sistema proposto fornece classificação ótima utilizando Redes Neurais Convolucionais Profundas (do inglês Deep Convolutional Neural Networks – DCNN) aliadas à Matriz de Co-ocorrência de Nível de Cinza (do inglês Gray Level Co-occurrence Matrix – GLCM) (GAURAPPAWAR et al., 2020).

Em consonância com a afirmação anterior, o trabalho de Athiraja e Vijayakumar (2021) comprova que é possível diagnosticar doenças na bananeira utilizando visão computacional e métodos de aprendizado de máquina. Foram coletadas imagens e foi feita a remoção de ruídos com a técnica de filtragem de núcleo suave. A detecção por computador é feita com a técnica de limiarização para localizar o exato ponto enfermo da imagem pré-processada. O diagnóstico utiliza o sistema de inferência neuro fuzzy adaptativo (do inglês adaptive neuro fuzzy inference system – ANFIS) para categorizar as células doentes em: originais, muito pequenas, minúsculas, médias, altas e muito altas. Para avaliar a eficiência do esquema, foi utilizada a curva de características operacionais do receptor (do inglês receiver operating characteristics – ROC) e a precisão foi de 97,5%.

Ridhovan et al. (2022) constata que doenças em folhas de bananeira podem ser detectadas em imagens em condições de luminosidade, a partir da aplicação de aprendizado profundo com os modelos DenseNet e Inception. O modelo resultante categorizou as folhas de bananeira em saudáveis, infectadas com cordana, infectadas com sigatoka e infectadas com pestalotiopsis. Com base na avaliação de desempenho, é possível concluir que o modelo de aprendizado de máquina com o DenseNet tem desempenho superior aos outros modelos de aprendizado de máquina, com valor percentual de 84,73% de acurácia, precisão de 84,80% e lembrança de 84,73%.

Kawatra, Agarwal e Kapur (2020) apresentam uma abordagem que aplica três modelos criados com o AlexNet como base em CNNs. O primeiro modelo utiliza a arquitetura básica do AlexNet, sendo o melhor resultado dado pelo otimizador AdaMax com precisão de 96,34%. O segundo modelo é a combinação de AlexNet e camada média global de agrupamento (GAP layer). O terceiro é a combinação de AlexNet e máquina de vetores de suporte (do inglês support vector machines – SVM), que atingiu uma precisão de 99,98%.

Raghavendra et al. (2022) faz uma abordagem da estrutura de um sistema de classificação de banana que usa imagens RGB para criar um novo modelo de aprendizado profundo de múltiplas entradas. A técnica RGB1 é capaz de identificar elementos externos da banana: tamanho, cor e textura. A partir de uma combinação de CNN e perceptron de multicamadas (do inglês multilayer perceptron



– MLP) aplicada a características extraídas com RGB, o modelo de múltiplas entradas tem precisão de 98,4% para classificar as imagens das bananas.

Especificamente sobre a detecção da fusariose, Gaurappawar et al. (2020) vem trazer um sistema para a identificação e detecção de doenças nas folhas de bananeira. O sistema utiliza CNN para extrair características de imagens e o algoritmo k-vizinho mais próximo (do inglês k-nearest neighbor – KNN) para prever doenças. De acordo com os autores, o sistema prevê doenças da bananeira como sigatoka negra, sigatoka amarela e mal-do-Panamá. Fornece relatório dos sintomas da doença identificada e notifica o usuário sobre o acometimento nas folhas da bananeira.

Tsai, Chen e Tsai (2019) propõem em sua pesquisa uma CNN eficaz intitulada de MResNet, exatamente para detecção do mal-do-Panamá. A abordagem exposta se baseia no ResNet-34 com função de ativação de ReLUs. Os resultados desse trabalho identificam que a técnica MResNet é superior a outras CNNs, como LeNet-5, VGG-16, VGG-19, ResNet-34, ResNet-50. Apresenta valores de precisão e lembrança altos.

Diante do exposto, a detecção de doenças foliares na bananeira é uma ferramenta importante para o desenvolvimento da bananicultura. Para isso, é necessária a aplicação de modelos baseados em aprendizado profundo por meio de CNNs. Na seção seguinte, será apresentado um modelo de rede neural profunda para ser aplicado nesse processo.

3 ABORDAGEM METODOLÓGICA

Para realizar a detecção da doença mal-do-Panamá, técnicas de extração de características em imagens foram aplicadas a partir da criação e do treinamento de modelos de Redes Neurais Convolucionais (CNNs).

3.1 BANCO DE DADOS PARA DETECÇÃO DA DOENÇA

Neste trabalho, foram utilizadas as bases de dados de imagens propostas por Hailu (2021), Medhi e Deb (2022), as quais possuem, originalmente, 6.459 imagens de doenças foliares nos dois conjuntos de dados, classificadas em 09 (nove) categorias: a) folhas de bananeiras sadias (155 imagens); b) folhas de bananeiras infectadas por murcha bacteriana (*xanthomonas campestris* pv. *viticola*) (814 imagens); c) folhas de bananeiras infectadas por sigatoka amarela (584 imagens) e negra (474 imagens); d) folhas de bananeiras infectadas por podridão bacteriana (1.078 imagens); e) folhas de bananeiras infectadas por besouro marrom (150 imagens); f) folhas de bananeiras infectadas por mal-do-Panamá (102 imagens); g) folhas de bananeiras infectadas por pulgões (366 imagens); h) folhas de bananeiras infectadas por gorgulho do pseudocaulo (2.736 imagens).

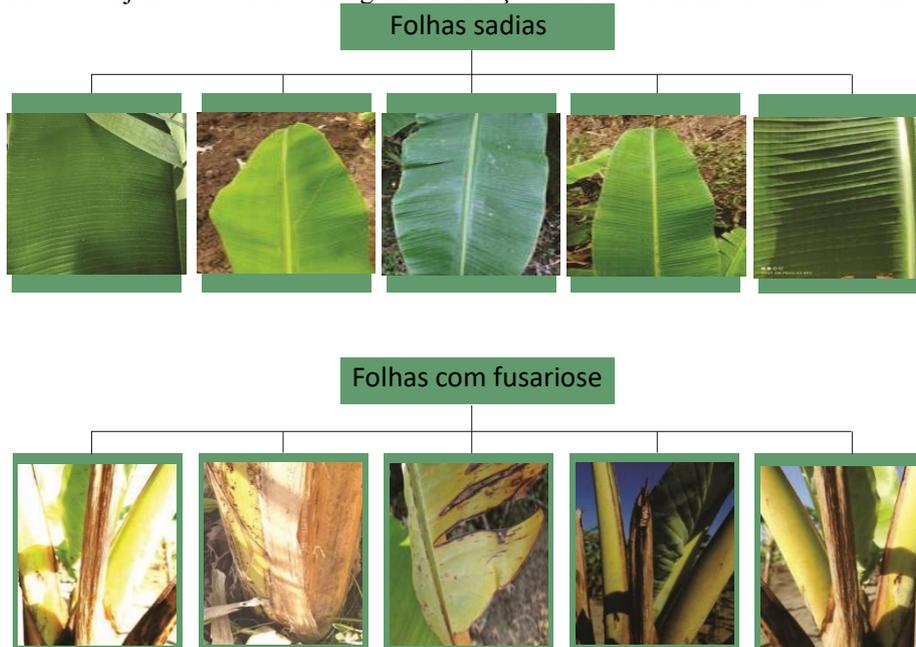
A fim de aumentar o conjunto de dados, recrutou-se um especialista em patologias de plantas para coletar e aumentar o número de imagens com a doença foliar do mal-do-Panamá, sendo coletada



diretamente das culturas de bananeiras na região do oeste baiano, especificamente, no projeto de irrigação Formoso¹, na cidade de Bom Jesus da Lapa, Bahia, Brasil.

O conjunto de dados final utilizado neste trabalho é composto por 6.788 imagens, separadas em 09 (nove) categorias de doenças foliares. Neste estudo, focou-se apenas nas imagens das folhas com o mal-do-Panamá (102 imagens) e folhas saudias (264 imagens). A Figura 1 representa uma amostra do conjunto de dados categorizados com folhas saudias e folhas acometidas pelo mal-do-Panamá.

Figura 1 – Conjunto de dados de imagens da doença da mal-do-Panamá na folha da bananeira.



Fonte: Autores (2023).

3.2 PREPARAÇÃO E PRÉ-PROCESSAMENTO DE IMAGENS

Durante o processo de aquisição de imagens para o treinamento de redes neurais artificiais pode ocorrer alguns ruídos, distorções ou variações desnecessárias nas imagens. Desta forma, o pré-processamento é uma etapa obrigatória na maioria das tarefas de detecção e classificação de objetos.

3.2.1 Problemas com Sobreajuste

Conforme observado por Azimi et al. (2021), um pequeno número de entradas de treinamento tende a conduzir o modelo de classificação ao sobreajuste (do inglês overfitting), isto é, um ajuste excessivo ao conjunto de treinamento, prejudicando a acurácia na classificação das novas entradas. Na aprendizagem de máquina, o sobreajuste é um comportamento indesejável que ocorre quando a rede

¹ O Formoso é um Projeto Público de Irrigação (PPI) constituído pelas etapas Formoso A e Formoso H, que contribui para o desenvolvimento regional por meio da agricultura irrigada na produção de alimentos, com predominância de exploração da bananicultura, que correspondeu a 90% da área plantada em 2021 (CODEVASF, 2022).



neural artificial fornece previsões precisas para dados de treinamento, mas não para novos dados (MUTASA; SUN; HA, 2020).

3.2.2 Aumento de Dados Artificiais

Para evitar problemas com overfitting ou sobreajuste, a criação de dados artificiais a partir da base real, adicionando os novos dados ao grupo de treinamento original pode ser uma possível solução (STRASHKO; STOUDEMIRE, 2022). Esse processo é conhecido por aumento de dados artificiais (do inglês data augmentation).

As técnicas utilizadas para aumentar artificialmente o conjunto de dados foram a inversão de imagens, correção de gama, injeção de ruído, aumento de cores da análise do componente principal (do inglês Principal Component Analysis - PCA), rotação e transformações de dimensionamento. Cada uma das imagens passou pelo mesmo tratamento antes de servir como entrada para o treinamento do modelo. Inicialmente, foi dado a cada imagem um rótulo com o nome da classe à qual pertence.

3.2.3 Redimensionamento de Imagem

Por motivos de limitação computacional do ambiente de execução, as gravuras foram redimensionadas para um tamanho de 150x150 pixels. Tal transformação se fez necessária, pois a carga das imagens em seu tamanho original na memória ultrapassa os limites disponíveis no ambiente de execução.

3.2.4 Transformação da Imagem

Cada imagem foi segmentada em uma matriz computacional tridimensional armazenando os pixels verticais e horizontais da imagem com base nas cores RGB. Sua função de medição de transformação é demonstrada pela equação:

$$PGS = (PRed \times 0.3) + (PGreen \times 0.59) + (PBlue \times 0.11) \quad (1)$$

Onde P denota o valor do pixel correspondente da imagem (GS).

3.2.5 Filtragem de Imagem

Essa é a última etapa do pré-processamento, a qual filtra blocos indesejáveis da imagem. Após a obtenção dos dados básicos para o processo de filtragem, outros blocos indesejáveis da imagem podem ser novamente filtrados e a imagem completa torna-se pronta para utilização posterior:

$$f(i) = \max(0, i) \quad (2)$$

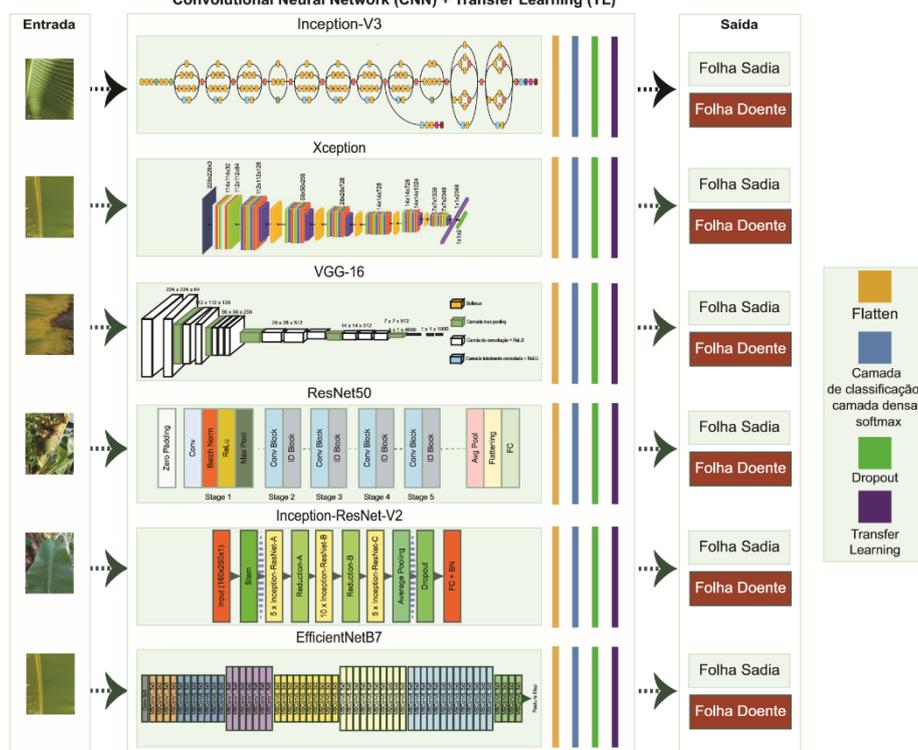


Onde o termo i denota os valores positivos das imagens de entrada. Neste sentido, cada bloco de imagem complexo é continuamente filtrado com base na função de ativação ReLU. Isso garante uma sequência de imagem clara, retornando para cada uma das duas classes de imagens (folhas saudáveis e folhas doentes) um número inteiro distinto entre 0 e 1.

3.3 MODELOS DE CLASSIFICAÇÃO CONVOLUCIONAIS

O modelo de classificação é formado pela base convolucional e pela camada de classificação. A primeira realiza a extração das características de interesse das imagens convertidas em matrizes; a última recebe o resultado da etapa anterior e realiza a classificação da imagem (Figura 2).

Figura 2 – Arquiteturas dos modelos CNN e Deep Transfer Learning para classificação de imagens (CNN-TL).



Fonte: Autores (2023).

Para a base convolucional, foram selecionados e testados 06 (seis) modelos neurais pré-treinados do estado da arte: Inception-v3, Xception, VGG-16, ResNet50, Inception-ResNet-v2 e EfficientNetB7.

3.4 TRANSFERÊNCIA DE APRENDIZADO

A Transferência de Aprendizagem (do inglês, Transfer Learning – TL), foi usada no treinamento, ou melhor, retreinamento do modelo. Baker, Zengeler e Handmann (2022) trazem a TL como um algoritmo que utiliza o conhecimento adquirido e os recursos de uma rede já treinada para cumprir papel similar em um novo conjunto de dados. Todas as implementações de arquiteturas do



estado da arte foram obtidas e estão disponíveis no Framework Tensorflow, sob licenças de código aberto.

4 EXPERIMENTOS

Os modelos pré-treinados definidos foram aplicados e avaliados a partir de métricas utilizadas na literatura. As etapas e ferramentas são descritas na sequência.

4.1 TENSORFLOW E KERAS

O Google Collaboratory é um projeto cuja finalidade se concentra na disseminação do conhecimento acerca do aprendizado de máquina e no apoio de pesquisas sobre o tema, tendo como base a ferramenta Jupyter Notebook.

De acordo com Carneiro et al. (2018), a plataforma fornece ambientes em diferentes versões do Python, já pré-configurados com as bibliotecas necessárias, por exemplo, o TensorFlow e o Keras. Por fim, essa ferramenta disponibiliza um serviço de processamento em tempo de execução acelerado por Unidade de Processamento Gráfico (do inglês Graphics Processing Unit – GPU).

4.2 CONFIGURAÇÕES DOS EXPERIMENTOS

A combinação da camada de classificação construída com o extrator de características de cada uma das 06 (seis) arquiteturas pré-treinadas criou 06 (seis) novos modelos de classificação. Cada novo modelo foi treinado da seguinte forma: empregou-se 80% das imagens, escolhidas aleatoriamente. Os outros 20% de imagens serviram como dados de teste para avaliar a eficácia. Durante o treinamento, foram definidos hiperparâmetros para melhorar a acurácia. A Tabela 1 os apresenta junto aos seus respectivos valores.

Tabela 1 – Hiperparâmetros da rede neural profunda.

Hiperparâmetro	Valor
Épocas de treinamento	30
Tamanho do lote	32
Passos por época	133
Taxa de dropout	0.4

Fonte: Autores (2023).

Com o intuito de evitar problemas com overfitting, aplicou-se uma técnica adicional durante o treinamento, a Redução da Taxa de Aprendizagem no algoritmo. Esse método reduz, a cada época de treinamento, a taxa de aprendizagem quando uma métrica se torna ineficiente. Neste sentido, a taxa adotada pelo modelo foi 1×10^{-5} . Além disso, adotou-se a função Adam como otimizador estocástico (Algoritmo 1).



Algoritmo 1 - Algoritmo da função de otimização Adam

Require: α : tamanho do passo
Require: $\beta_2, \beta_1 \in [0,1)$: taxas de decaimento exponencial para as estimativas de momento
Require: $f(0)$: função objetivo estocástica com parâmetros 0
Require: θ_0 : vetor de parâmetros inicial
 1: $m_0 \leftarrow 0$ (inicializar vetor de 1º momento)
 2: $v_0 \leftarrow 0$ (inicializar vetor do 2º momento)
 3: $t_0 \leftarrow 0$ (inicializar passo de tempo)
 4: **while** θ_t não convergente **do**
 5: $t \leftarrow t + 1$
 6: $g \leftarrow \nabla_{\theta} f_t(\theta_t - 1)$ (obter gradientes w.r.t. em relação à função objetivo estocástico no passo de tempo t)
 7: $m_t \leftarrow \beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot g_t$ (atualizar estimativa do primeiro momento bruto enviesado)
 8: $v_t \leftarrow \beta_2 \cdot v_{t-1} + (1 - \beta_2) \cdot g_t$ (atualizar estimativa do segundo momento bruto enviesado)
 9: (calcular a estimativa do primeiro momento corrigida pelo viés)
 10: (calcular a estimativa do segundo momento bruto corrigida pelo viés)
 11: (atualizar parâmetros)
 12: **end while**
 13: **retornar** θ_t (parâmetros resultantes)

Fonte: Autores.

Onde α representa a taxa de aprendizado para a etapa de descida do gradiente, β_1 é o parâmetro para passo de momento (também conhecido como primeiro momento em Adam), β_2 o parâmetro para o passo do RMSProp (também conhecido como segundo momento em Adam), ϵ o parâmetro para estabilidade numérica. Enquanto m e v são as estimativas do primeiro e segundo momento, respectivamente. Já t é o parâmetro timestep para etapas de correção de viés e $(g$ e $f)$ são os valores de gradiente e a função em θ . Por fim, a função de otimização Adam pode ser entendida como a combinação dos algoritmos Momentum e RMSProp.

Não obstante, nos modelos em questão foi observada a acurácia da validação no conjunto de testes. A taxa era reduzida a um fator de 0.1 (isto é, a nova taxa é calculada pela multiplicação da atual por 0.1) a cada 5 passos ou épocas consecutivas em que a acurácia da validação não sofresse uma mudança significativa. A acurácia de cada modelo foi validada utilizando os seguintes passos: durante cada época de treinamento o estado atual da rede era utilizado para classificar o conjunto de dados de teste anteriormente discriminado.

4.3 MÉTRICAS PARA AVALIAÇÃO DO MODELO

Realizaram-se as avaliações dos modelos propostos nos conjuntos de dados com as métricas de avaliações: acurácia (ACC), f1-score, área sob a curva (AUC) e erro médio quadrático (MSE).

4.3.1 Métrica de Avaliação de Acurácia (ACC)

A métrica de avaliação de acurácia (ACC) é a razão entre o número de previsões corretas e o número total de amostras de entrada, como pode ser visualizado na equação a seguir:



$$ACC = \frac{\text{Número de previsões corretas}}{\text{Número total de previsões realizadas}} \quad (3)$$

4.3.2 Métrica de Avaliação F1-Score (F1)

A métrica de avaliação f1-score (F1) é a média harmônica entre precisão e lembrança. O intervalo para f1-score é [0, 1], que indica a precisão do classificador. Sendo assim, quanto maior o f1-score, melhor o desempenho do modelo. Isso pode ser expresso matematicamente como:

$$F1 = 2 \cdot \frac{1}{\frac{1}{\text{precisão}} + \frac{1}{\text{lembrança}}} \quad (4)$$

4.3.3 Métrica de Avaliação Área Sob a Curva (AUC)

A métrica área sob a curva (AUC) é utilizada para problemas de classificação binária. A AUC de um classificador é igual à probabilidade de que o classificador tem de classificar um exemplo positivo escolhido aleatoriamente mais alto do que um exemplo negativo escolhido aleatoriamente.

4.3.4 Métrica de Avaliação Erro Médio Quadrático (MSE)

O erro médio quadrático (do inglês mean squared error – MSE) é semelhante ao erro médio absoluto (do inglês mean absolute error - MAE). A diferença é que o MSE obtém a média do quadrado da diferença entre os valores originais e os valores previstos. A Métrica MSE pode ser definida pela equação:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5)$$

5 RESULTADOS E DISCUSSÕES

O conjunto de dados foi dividido em dois subconjuntos, treinamento e teste, cujas imagens foram etiquetadas com uma das 02 (duas) diferentes classes de folhas vegetais (saudáveis e enfermas). Com isso, foi possível avaliar a performance dos modelos baseados nas arquiteturas Inception-v3, Xception, VGG-16, ResNet50, Inception-ResNet-v2 e EfficientNetB7. Por fim, realizou-se estudo comparativo entre os modelos propostos com base nas métricas ACC, F1-Score, AUC e MSE.

5.1 COMPARATIVO ENTRE AS ARQUITETURAS PROPOSTAS

À medida que os 6 modelos concebidos foram treinados por 30 épocas cada e reavaliados com o mesmo conjunto de teste ao final de cada passo, foi possível acompanhar a evolução gradativa. A



execução do algoritmo gerou a avaliação dos modelos com base em: Métrica de Avaliação Acurácia (ACC), Métrica de Avaliação F1-Score (F1), Métrica de Avaliação Área Sob a Curva (AUC) e Métrica de Avaliação Erro Médio Quadrático (MSE).

A submissão dos modelos ao subconjunto de teste permitiu obter os valores das métricas mencionadas. A Tabela 2 traz a relação entre base convolucional usada e esses valores obtidos, além do tempo de treinamento de cada modelo.

Tabela 2 – Comparativo das métricas de avaliação entre os modelos

Modelo CNN	ACC	F1-Score	AUC	MSE	Tempo (s)
Xception	1.0000	1.0000	1.0000	0.0000	309.230095
VGG16	0.9967	0.9969	0.9969	0.0033	325.676256
ResNet50	1.0000	1.0000	1.0000	0.0000	285.350383
Inception-v3	1.0000	1.0000	1.0000	0.0000	199.457401
InceptionResNet-v2	0.9837	0.9848	0.9829	0.0163	486.318909
EfficientNetB7	1.0000	1.0000	1.0000	0.0000	1235.352004

Fonte: Autores (2023).

Diante do exposto, é possível inferir que as redes baseadas em Inception-v3, Xception, Resnet50 e EfficientNetB7 foram as mais assertivas. Os modelos alcançaram o surpreendente resultado de 1 de acurácia (ACC) e igual valor de AUC e F1-Score; na métrica MSE, os quatro alcançaram o valor de 0.0, o que é excelente.

O destaque maior é do modelo baseado na arquitetura Inception-v3, que, além da acurácia máxima, foi o que demandou menos tempo de execução, cerca de 199 segundos. Em contraponto a isso, a rede neural mais longa foi a EfficientNetB7, que demandou cerca de 1235 segundos para realizar o treinamento.

Paralelamente, a rede que desempenhou resultados menos expressivos foi a InceptionResNet-V2. Marcou-se 0.9837 de acurácia (ACC), 0.9829 de AUC, 0.0163 de MSE e 0.9848 de F1-Score. Além disso, foi o segundo treinamento mais longo, realizado em cerca de 486 segundos. É necessário pontuar que os valores obtidos são altamente satisfatórios.

6 CONCLUSÕES

O presente estudo propôs avaliar um modelo baseado em transferência de aprendizado profundo para detecção da fitopatologia foliar mal-do-Panamá na cultura da banana. Verificou-se a precisão em testes feitos com 06 (seis) configurações diferentes de um algoritmo executado no Google Colaboratory, processando duas classes (sadias e doentes) de imagens de folha da bananeira.

Entre os avaliados, destacou-se a versão do modelo baseado na arquitetura Inception-v3, que alcançou pontuação máxima nas métricas de avaliação utilizadas de ACC, AUC, MSE e F1-Score. Note-se ainda que essa foi a rede neural a demandar menos tempo de treinamento, de cerca de 199



segundos. Não obstante, todos os modelos treinados apresentaram desempenho altamente satisfatório, principalmente na métrica de acurácia, com aproveitamento geral acima de 98%.

Portanto, o modelo de melhor desempenho apresentou-se como solução viável à detecção da fusariose, devido à acurácia e ao tempo de treinamento. Isto corrobora o resultado das pesquisas no estado da arte: modelos de aprendizado profundo podem ser aplicados para detecção de doenças na cultura banana. A identificação ágil deve auxiliar o bananicultor à tomada de decisão em tempo hábil. Pesquisas futuras podem estender essa aplicação para diferentes culturas, além de utilizar abordagens com outras doenças foliares e até mesmo em outras partes da planta.



REFERÊNCIAS

- ALMEYDA, Estefani; IPANAQUÉ, William. Recent developments of artificial intelligence for banana: Application areas, learning algorithms, and future challenges. *Engenharia Agrícola*, v. 42, p. e20210144, 2022.
- ATHIRAJA, A.; VIJAYAKUMAR, P. Retracted article: Banana disease diagnosis using computer vision and machine learning methods. *Journal of Ambient Intelligence and Humanized Computing*, v. 12, n. 6, p. 6537-6556, 2021.
- AZIMI, Sepideh Alsadat et al. Classification of radioxenon spectra with deep learning algorithm. *Journal of Environmental Radioactivity*, v. 237, p. 106718, 2021.
- ABOU BAKER, Nermeen; ZENGELER, Nico; HANDMANN, Uwe. A transfer learning evaluation of deep neural networks for image classification. *Machine Learning and Knowledge Extraction*, v. 4, n. 1, p. 22-41, 2022.
- BEGUM, A. Sumaiya et al. Diagnosis of leaf disease using enhanced convolutional neural network. *Int. J. Innov. Res. Appl. Sci. Eng.*, v. 3, n. 12, p. 579-586, 2020.
- CARNEIRO, Tiago et al. Performance analysis of google colab as a tool for accelerating deep learning applications. *Ieee Access*, v. 6, p. 61677-61685, 2018.
- CODEVASF. Formoso A/H. 2022. Disponível em: <<https://www.codevasf.gov.br/linhasde-negocio/irrigacao/projetos-publicos-de-irrigacao/elenco-de-projetos/emproducao/formoso-a-h>>.
- DHAKA, Vijaypal Singh et al. A survey of deep convolutional neural networks applied for prediction of plant leaf diseases. *Sensors*, v. 21, n. 14, p. 4749, 2021.
- EMBRAPA. Banana. 2022. Disponível em: <<https://www.embrapa.br/agencia-de-informacaotecnologica/cultivos/banana>>.
- EUNICE, Jennifer et al. Deep learning-based leaf disease detection in crops using images for agricultural applications. *Agronomy*, v. 12, n. 10, p. 2395, 2022.
- GAURAPPAWAR, P. et al. Banana leaf and stem disease detection by using classification technique. *IJFMR-International Journal For Multidisciplinary Research, IJFMR*, v. 2, n. 1, p. 1-4, 2020.
- GAUTAM, Vinay et al. A transfer learning-based artificial intelligence model for leaf disease assessment. *Sustainability*, v. 14, n. 20, p. 13610, 2022.
- HAILU, Y. Banana leaf disease images. *Mendeley Data*, v. 1, 2021. 7
- KAWATRA, Mihir; AGARWAL, Shreyas; KAPUR, Raghu. Leaf disease detection using neural network hybrid models. In: 2020 IEEE 5th international conference on computing communication and automation (ICCCA). IEEE, 2020. p. 225-230.
- KHAMPARIA, Aditya et al. Seasonal crops disease prediction and classification using deep convolutional encoder network. *Circuits, Systems, and Signal Processing*, v. 39, n. 2, p. 818-836, 2020.
- KRISHNAN, V. Gokula et al. An automated segmentation and classification model for banana leaf disease detection. *Journal of Applied Biology and Biotechnology*, v. 10, n. 1, p. 213-220, 2022.



- LI, Lili; ZHANG, Shujuan; WANG, Bin. Plant disease detection and classification by deep learning—a review. *IEEE access*, v. 9, p. 56683-56698, 2021.
- MAHENDRAN, T.; SEETHARAMAN, K. Banana Leaf Disease Detection Using Glcm Based Feature Extraction And Classification Using Deep Convoluted Neural Networks (Dcnn). *Journal of Positive School Psychology*, v. 6, n. 10, 2022.
- MEDHI, Epsita; DEB, Nabamita. PSFD-Musa: A dataset of banana plant, stem, fruit, leaf, and disease. *Data in brief*, v. 43, p. 108427, 2022.
- MUHAMMAD, Marinah; ZAWAWI, Muhammad Akmal Mohd; JEMALI, N. Incorporating the Plant Disease Triangle Framework for Analyzing the Effect of FWB Incidence on Soil Attributes. *Israa University Journal of Applied Science*, 2023.
- MUTASA, Simukayi; SUN, Shawn; HA, Richard. Understanding artificial intelligence based radiology studies: What is overfitting?. *Clinical imaging*, v. 65, p. 96-99, 2020.
- NANDHINI, M. et al. Applicability of deep learning techniques for crop protection in plantain tree cultivation. *Indian Journal of Computer Science and Engineering*, v. 12, n. 1, p. 1-9, 2021.
- RAGHAVENDRA, S. et al. Deep learning based dual channel banana grading system using convolution neural network. *Journal of Food Quality*, v. 2022, 2022.
- RIDHOVAN, Andreanov et al. Disease detection in banana leaf plants using densenet and inception method. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, v. 6, n. 5, p. 710-718, 2022.
- SANGEETHA, Ramachandran et al. An improved agro deep learning model for detection of Panama wilts disease in banana leaves. *AgriEngineering*, v. 5, n. 2, p. 660-679, 2023.
- STRASHKO, Artem; SToudenMIRE, E. Miles. Generalization and overfitting in matrix product state machine learning architectures. *arXiv preprint arXiv:2208.04372*, 2022.
- TEJASWINI, Pallapothala et al. Rice leaf disease classification using CNN. In: *IOP Conference Series: Earth and Environmental Science*. IOP Publishing, 2022. p. 012017.
- TSAI, Cheng-Fa; CHEN, Yu-Chieh; TSAI, Chia-En. Real life image recognition of Panama disease by an effective deep learning approach. In: *2019 International Conference on Machine Learning and Cybernetics (ICMLC)*. IEEE, 2019. p. 1-5.
- TUGRUL, Bulent; ELFATIMI, Elhoucine; ERYIGIT, Recep. Convolutional neural networks in detection of plant leaf diseases: A review. *Agriculture*, v. 12, n. 8, p. 1192, 2022.
- YADHAV, S. Yegneshwar et al. Plant disease detection and classification using cnn model with optimized activation function. In: *2020 international conference on electronics and sustainable communication systems (ICESC)*. IEEE, 2020. p. 564-569.

