

# IDENTIFICAÇÃO DE BICHO-MINEIRO E DE FERRUGEM NO CAFEEIRO UTILIZANDO PROCESSAMENTO DIGITAL DE IMAGENS E REDES NEURAIS CONVOLUCIONAIS

## IDENTIFICATION OF COFFEE LEAF MINER AND RUST IN COFFEE PLANTS USING DIGITAL IMAGE PROCESSING AND CONVOLUTIONAL NEURAL NETWORKS

Recebido em: 14/11/2023

Reenviado em: 02/09/2024

Aceito em: 21/09/2024

Publicado em: 21/10/2024

Charly Braga Ventura<sup>1</sup>   
Universidade Federal de Itajubá

Érick Oliveira Rodrigues<sup>2</sup>   
Universidade Tecnológica Federal do Paraná

Vanessa Andaló Mendes de Carvalho<sup>3</sup>   
Universidade Federal de Uberlândia

Sandro Carvalho Izidoro<sup>4</sup>   
Universidade Federal de Itajubá

**Resumo:** A demanda do mundo por café aumenta a cada ano, e o Brasil é um dos maiores produtores globais. Com o elevado volume de produção, há uma necessidade crescente de melhoria da qualidade do produto devido às exigências dos mercados nacional e internacional. Porém, pragas como o bicho mineiro (*Leucoptera coffeella*) e a ferrugem (*Hemileia vastatrix*) causam grandes danos em plantações de café, resultando em perdas da cultura anualmente. Vários métodos e técnicas vêm sendo desenvolvidas e aplicadas para avaliação do nível de infestação e controle destas pragas. Entre essas técnicas estão o uso de Visão Computacional e Rede Neural Convolucional (CNN). Assim, o objetivo deste trabalho foi o desenvolvimento de uma ferramenta computacional para identificar corretamente a presença de pragas, reduzindo o tempo de avaliação, o erro do avaliador e os gastos com mão de obra. A acurácia dos métodos desenvolvidos ficou entre 99,67% e 97,00%.

**Palavras-chave:** *Deep Learning*, Visão Computacional, Rede Neural Convolucional, *Leucoptera Coffeella*, *Hemileia Vastatrix*.

**Abstract:** The world's demand for coffee increases every year, with Brazil being one of the largest global producers. With the high volume of production, there is a growing need to improve product quality due to the demands of national and international markets. However, pests such as leaf miner (*Leucoptera coffeella*) and rust (*Hemileia vastatrix*) cause extensive damage to coffee plantations, resulting in crop losses annually. Various methods and techniques have been developed and applied to assess the level of infestation and control of these

<sup>1</sup> Aluno do Programa de Pós-graduação em Ciência e Tecnologia da Computação da Universidade Federal de Itajubá. Email: charly@unifei.edu.br

<sup>2</sup> Professor do Programa de Pós-graduação em Engenharia de Produção e Sistemas da Universidade Tecnológica Federal do Paraná. E-mail: erickrodrigues@utfpr.edu.br

<sup>3</sup> Professora do Programa de Pós-graduação em Agricultura e Informações Geoespaciais e do Programa de Pós-graduação em Agronomia da Universidade Federal de Uberlândia. Email: vanessaandalo@ufu.br

<sup>4</sup> Professor do Programa de Pós-graduação em Ciência e Tecnologia da Computação da Universidade Federal de Itajubá. E-mail: sandroizidoro@unifei.edu.br

pests. Among these techniques are the use of computer vision and convolutional neural networks (CNN). Thus, the objective of this work was to develop a computational tool to correctly identify the presence of pests, reducing evaluation time, evaluator error, and labor costs. The accuracy of the methods developed was between 99.67% and 97.00%.

**Keyword:** Deep Learning, Computer Vision, Convolutional Neural Network, *Leucoptera Coffeella*, *Hemileia Vastatrix*,

## INTRODUÇÃO

A agropecuária é um dos principais pilares dos setores da economia brasileira, contribuindo com geração de emprego, renda e riqueza para a nação (OLIVEIRA *et al.*, 2014). O café é uma das *commodities* mais importante do Brasil, com exportações de 3,157 milhões de sacas de 60 kg em junho de 2019. Em 2020, segundo dados da Empresa Brasileira de Pesquisa Agropecuária (Embrapa) (2021), a produção total foi de 63,07 milhões de sacas de 60 kg. A Embrapa (2021) estima que a receita cambial gerada pelas exportações de café do Brasil em 2020 foi de R\$5,6 bilhões, um acréscimo de 10,3% em comparação com 2019, demonstrando o potencial nacional no aumento da produção da cultura. Já dados mais recentes da Embrapa (2023), estimou que a produção mundial de café 2022/2023 seria de 171,3 milhões de sacas de 60kg, porém com demanda superior a oferta, 178,5 milhões de sacas de 60kg para este período. Tanto a produção como a demanda tiveram acréscimo de 1,7% em relação ao período anterior de 2021/2022. A Embrapa demonstra que tanto a produção como a demanda de café aumentam a cada ano, o que significa que é de grande importância cultura a nível mundial.

O fato de o Brasil ser o maior produtor e exportador de café do mundo faz aumentar a exigência na qualidade dos grãos de café (SOARES *et al.*, 2019). Uma das formas de melhorar a qualidade da cultura de café é combater estresses bióticos, como a ocorrência de artrópodes-pragas e doenças, que afetam as plantações, levando à desfolhação e redução da fotossíntese, reduzindo assim o rendimento e qualidade do produto final (VENTURA *et al.*, 2017).

Vários métodos e técnicas computacionais vêm sendo desenvolvidas e aplicadas para avaliação do nível de infestação e controle destas pragas. Devido à importância da área para o Brasil, boa parte dos trabalhos publicados é nacional. Entre as técnicas mais utilizadas podem-se destacar Redes Neurais Artificiais (ANN) e Redes Neurais Convolucionais (CNN), K-means, Árvore de Decisão, *Random Forest* (RF), *Support Vector Machines* (SVM). Grande parte das arquiteturas pré-treinadas, como ResNet e GoogleNet, implementam a técnica CNN.

As CNNs simulam o mecanismo de processamento visual do cérebro, no qual elementos complexos são gradualmente identificados a partir de características básicas, como as linhas de uma imagem (FACELI *et al.*, 2021, p. 114).

A estrutura de uma CNN tem várias etapas, por onde as imagens passam e são reduzidas gradativamente, tendo suas características extraídas (MARCOS; RODOVALHO; BACKES, 2019).

O objetivo deste trabalho é desenvolver um sistema para identificação de doenças causadas pelo bicho-mineiro (*Leucoptera coffeella*) e pela ferrugem (*Hemileia vastatrix*) em folhas de pé de café utilizando processamento digital de imagens e redes neurais convolucionais. Os objetivos específicos são:

- Selecionar conjunto de dados com imagens de pés de café com destaque para folhas, que sejam públicos, para serem utilizados neste trabalho.
- Realizar pré-processamentos para preparar o conjunto de dados para a etapa de treinamento/aprendizagem.
- Aumentar o conjunto de dados artificialmente para balanceá-lo utilizando a técnica de *data augmentation*.
- Implementar CNNs para detectar sintomas do bicho-mineiro e ferrugem;
- Treinar modelos CNNs com dados existentes e comparar os resultados entre as técnicas.
- Comparar os resultados deste trabalho com outros estudos da mesma área.

## REVISÃO BIBLIOGRÁFICA

A espécie *Leucoptera coffeella*, popularmente conhecida como bicho-mineiro, destaca-se como uma mariposa de tonalidade branca prateada, cuja dieta se restringe inteiramente ao cafeeiro, principalmente ao tecido do parênquima foliar. Esse hábito alimentar resulta na formação de minas, originando assim o nome popular (MOURA *et al.*, 2019; VIDAL *et al.*, 2019). O ciclo de vida desse inseto transcorre por quatro estágios ao longo de um intervalo de 19 a 50 dias: ovo, larva, pupa e adulto (MENDONÇA, 2021). Moura *et al.* (2019) afirmam que o bicho-mineiro ocasiona significativas perdas econômicas, decorrentes da diminuição da produtividade devido à redução da área foliar e à desfolha ocasionada.

A Imagem 1 ilustra um exemplo de folha saudável (esquerda), e uma outra folha atingida pelo bicho-mineiro. Moura *et al.* (2019) descreve que as minas construídas pelo

inseto possuem bordas irregulares, lesões irregulares de coloração parda com centro escuro, e a epiderme da folha de fácil remoção.

Imagem 1 – Folha de café saudável (esquerda) e minada (direita).



Fonte: Esgario, Krohling e Ventura, 2020.

Segundo Moura *et al.* (2019), a baixa precipitação, seca e maiores espaçamentos entre os plantios, que permite maior circulação de vento, favorecem a aparição da praga. Dantas *et al.* (2020) destaca que a forma de controle mais usual para este tipo de praga é biológico e químico, com foco maior em inseticidas. O autor também salienta que uso excessivo de agrotóxico é eficaz no controle de pragas, porém, além de gerar grande custo de aquisição e aplicação, contribui com problemas ambientais como contaminação de plantas, solo, corpos d'água e em alguns casos até mesmo o ar.

Segundo Castillo (2016), a obtenção de melhores resultados no controle do bicho-mineiro exige a utilização de um conjunto de métodos de controle. A amostragem é uma importante ferramenta que contribui no monitoramento da presença e índice populacional do inseto no campo, auxiliando na tomada de decisão para o controle da praga.

Outro problema relacionado às plantações de café são doenças causadas por fungos, como por exemplo, a ferrugem. Como pode ser visto na Imagem 2, a folha à esquerda representa um estágio mais inicial, com apenas manchas amarelo-alaranjada (clorose), enquanto à direita se tem um estágio mais avançado com manchas marrons (necrose). Os fungos compõem o grupo de maior diversidade patogênica em plantas com mais de 20.000 espécies, causando entre 70% a 80% de todas as doenças em vegetais, resultando em grandes danos ao cultivo e insegurança alimentar devido à baixa produtividade (CASTRO *et al.*, 2018).

Imagem 2 – Doença da ferrugem em estado inicial (esquerda) e avançado (direita).



Fonte: Esgario, Krohling e Ventura, 2020.

A doença da ferrugem do café, patógeno fúngico, é originária do leste da África e ganhou destaque a partir de 1869 (CARNEIRO; SILVA; FAULIN, 2021). Ela é considerada uma das mais prejudiciais da história e vem causando muitas perdas nos últimos 100 anos em todo o mundo. A doença é desenvolvida em clima úmido e é causada por fungos que infectam o pau do café e depois as folhas, deixando manchas amarelas, causando a queda das mesmas posteriormente, ao ponto de inutilizar parte da produção cafeeira (CABALLERO; DUKE, 2020).

Segundo Zambolim (2016), no Brasil, a ferrugem da folha do café é causada pelo fungo *Hemileia vastatrix*, que foi detectado pela primeira vez em *Coffea arabica* em janeiro de 1970, na região sul do Estado da Bahia. Hoje, a praga está presente em toda área de cultivo brasileira com arábicas e conilon, causando perdas que variam de 30% a 50%.

O fungo endofítico ataca folhas de pés de café adultos, principalmente plantas mais velhas e, se não controlada a infecção, pode resultar em até 45% de redução da produção cafeeira (MATIELLO, 1991).

Com o objetivo de identificar pragas do cafeeiro de forma automática, diversos métodos computacionais baseados em Inteligência Artificial (IA) e *Machine Learning* (ML) têm sido propostos na literatura.

Castro *et al.* (2018) implementaram um sistema capaz de identificar estresse em folhas de pés de café por meio do espectro de cores utilizando uma máquina com câmera espectral RESONOM modelo PIKA XC. O estudo coletou 140 imagens de folhas de pés de café do distrito de San Nicolas, província de Rodríguez de Mendonza na região da Amazônia. A base de dados foi constituída por 17 folhas saudáveis e 123 doentes com ferrugem, e foram definidos 5 níveis de saúde das folhas (de saudável até necrose causada pela ferrugem).

Os dados foram reduzidos com a técnica *Principal Component Analysis* (PCA), removendo ruídos e características que não interferem no resultado dos classificadores. Foram testados três diferentes classificadores: *Support Vector Machine* (SVM), *Decision Tree* e *K-nearest Neighbors*. O modelo SVM obteve o melhor resultado, com 94,7% de acurácia e 60% de falsos positivos.

Chemura, Mutanga e Sibanda (2018) utilizaram multi-espectro eletromagnético para identificar estresse biótico em folhas de pés de café. O estudo foi conduzido em uma estufa no Instituto de Pesquisa de Café, Chipinge, Zimbábue, onde as plantas foram semeadas e cultivadas, sendo inoculado nelas os patógenos após seis meses de idade, sendo climatizado o local para evolução das doenças. Um total de 63 amostras de imagens de folhas de pés de café foi utilizado, para classificar a gravidade da doença da ferrugem em três níveis: saudável, moderado (área afetada da folha entre 1% e 10%), e grave (acima de 10%). Para identificar estresse biótico nas plantas, o autor bombardeou diferentes espectros eletromagnéticos nas folhas, desde infravermelho até luz visível, e utilizou o sensor para identificar anomalias causadas pela ferrugem. Para fins de comparação, o trabalho utilizou dois algoritmos ML de regressão: *Radial Basis Function-partial Least Squares regression* (RBF-PLS) e *Partial Least Squared Regression* (PLSR). O melhor resultado para RBF-PLS foi  $R^2 = 92\%$  e  $RMSE=6,1\%$  e para PLSR foi  $R^2 = 27\%$  e  $RMSE=18,7\%$ .

Manso *et al.* (2019) criaram um aplicativo *mobile* para detectar e classificar ferrugem e minas. O autor utilizou o *smartphone* ASUS Zenfone 2 (ZE551ML) com resolução de 10 megapixels (4096 x 2304). O conjunto de dados de folhas inteiras contém um total de 690 amostras, divididas em três cores de fundos de imagens diferentes: branco, preto e azul. Assim, têm-se 174 folhas saudáveis com 58 para cada cor de fundo, 264 para minas com 88 para cada fundo, e 252 para ferrugem com 54 imagens para cada cor de fundo. Uma segunda base de dados foi criada com recortes de folhas inteiras com fundos brancos, resultando em 256 sintomas de minas e 759 de ferrugem. Para balanceá-la, o autor manteve apenas 256 amostras para cada classe de dados. Na fase de aprendizado, o trabalho utilizou uma *Artificial Neural Network Backpropagation* (ANN) com função de ativação ReLu e 13 diferentes configurações, como número de neurônios e taxas de aprendizado rodando 100 épocas cada, para comparar o desempenho entre elas. O autor ainda utilizou uma *Extreme Learning Machine* (ELM) com diferentes funções de ativação e quantidades de neurônios na camada oculta. O treino utilizou 70% dos dados disponíveis e teste 30%. O melhor resultado foi de  $96,013\% \pm 0,950$  de acurácia para ANN com 40 neurônios na cada oculta e taxa de

aprendizagem 0,1. Já para ELM o melhor resultado foi de 99,095%  $\pm$  0,007 de acurácia com 200 neurônios na cada oculta e função de ativação sigmoide.

Esgario, Krohling e Ventura (2020) utilizaram diversas arquiteturas CNN na identificação das doenças. O autor fotografou por meio de vários *smartphones* 1.747 imagens de folhas inteiras com fundo branco em laboratório, com quatro tipos de doenças: bicho-mineiro, ferrugem, phoma (mancha foliar marrom) e cercospora. Um segundo conjunto de dados com imagens com recorte de apenas sintomas específicos, utilizado apenas para identificar doenças, foi criado com um total de 2.722 figuras, sendo 2.147 da primeira base de dados deste mesmo trabalho e 572 de Barbedo (2019). A técnica de *augmentation* foi aplicada em todos os experimentos durante o treino das CNN com as transformações de rotações com espelhamento horizontal e vertical, rotação e variação de cor com brilho, contraste e saturação. Os autores também utilizaram transferência de aprendizado (*transfer learning*) para acelerar a convergência do treinamento, aproveitando o conhecimento já existente nas redes já pré-treinadas.

Esgario, Krohling e Ventura (2020) utilizaram as arquiteturas AlexNet, GoogleNet, VGG16, ResNet50 e ResNet50\* para os dois diferentes conjuntos de dados que também utilizaram o mesmo padrão anterior de classes (saudável, bicho-mineiro, ferrugem, phoma e cercospora), onde ranquearam essas classes em grau de severidade sendo saudável o grau mais leve e cercospora o grau mais severo, variando na seguinte ordem do melhor para o pior: (a) saudável, (b) bicho mineiro, (c) ferrugem, (d) phoma, e (e) cercospora. A rede VGG16 teve o melhor resultado para a análise de gravidade com 86,51% de acurácia.

Montalbo e Hernandez (2020) criaram uma CNN VGG16 pré-treinada para detectar doenças em folhas de pés de café do tipo Barako. O estudo utilizou um total de 3.958 imagens de folhas de café em alta resolução, colhidas das plantações das Filipinas. A divisão empregada pelos autores foi: 943 folhas saudáveis, sendo 804 para treino e 129 para validação; 1.727 com ferrugem, sendo 1.535 para treino e 182 para validação; 807 infestadas (por fungo ou parasita), tendo 694 para treino e 103 para validação; e 481 spots, com 386 para treino e 85 para validação. Para todas as categorias de dados foram utilizadas 10 imagens para a fase de teste da CNN. A resolução padrão inicial das figuras era de 3.120x3.120, transformadas posteriormente para 224x224 pelo modelo. A pesquisa utilizou ImageNet para transferir aprendizado para VGG16, compartilhando pesos sinápticos já treinados. Os autores definiram empiricamente os melhores valores de configurações, tendo três grupos de

configurações para serem comparadas, obtendo 100% de acurácia para duas delas e 98% para a terceira.

Esgario *et al.* (2021) criou um sistema de classificadores CNN com as arquiteturas UNet e PSPNet para identificar sintomas e mensurar gravidade em folhas de pés de café. Os *datasets* utilizados foram os mesmos do trabalho de Esgario, Krohling e Ventura (2018). UNet e PSPNet obtiveram 99,53% e 99,32% de acurácia, respectivamente. Ainda foi desenvolvido um aplicativo Android para captar imagens e identificar padrões nas folhas cafeeiras.

Carneiro, Silva e Faulin (2021) utilizaram a técnica *K-means* de forma semi-supervisionada na fase de pré-processamento para *clusterizar* e auxiliar na etiquetagem das imagens de folhas inteiras com doenças de ferrugem e bicho-mineiro (separando em graus de avanço da doença), com 285 e 257 unidades respectivamente, totalizando 542 figuras com resoluções iniciais de 4.000x2.250, e posteriormente reduzidas para 300x300 e 512x512, para serem testadas separadamente. Os autores utilizaram a técnica *k-means* para agrupar imagens sem rótulo às imagens com rótulo que eles já possuíam em sua base de dados.

Não foram utilizadas imagens de folhas saudáveis, tendo assim apenas duas classes de dados primários (bicho-mineiro e ferrugem). A técnica de *augmentation* adicionou novas imagens com transformações randômicas, como vertical, horizontal, recorte, redimensionamento, reposicionamento, contraste e brilho. Houve dois tipos de fase de extração de dados: sintomas de ferrugem e mina; e quantificação de gravidade da ferrugem. No primeiro caso, com 80% das imagens para treino e 20% para teste, foram utilizadas redes CNN Inception e ResNet50, que atingiram acurácias de 81,5% e 67%, respectivamente. Na quantificação, foi utilizada a técnica *Grabcut* com 5 iterações e *K-means* com 5 clusters que obteve melhor resultado com Afsoft, os quais estavam sendo comparados. Houve dificuldade para detectar doenças do tipo ferrugem, pelo fato das lesões serem menores que as minas, confundindo assim com reflexo da luminosidade, por exemplo.

É possível observar que existe uma predominância de Redes Neurais Convolucionais em praticamente todos os trabalhos relacionados da literatura. Também existe uma predominância de abordagens relacionadas na literatura que atingem ótimos resultados em tarefas de processamento de imagens desde o advento do *Deep Learning* (DL) (DONG; WANG; ABBAS, 2021). Desta forma, com base na literatura existente, o trabalho proposto será baseado em pré-processamento de imagens e CNNs. Além de utilizar modelos pré-

treinados, será desenvolvida uma CNN desde o início, sem utilizar modelos preexistentes. Além disso, uma nova metodologia de *data augmentation* também será implementada.

O processo de *data augmentation* consiste em gerar novas imagens baseadas nas imagens originais, ampliando a quantidade de amostras disponíveis para treinamento. Muitos dos princípios adotados em *data augmentation* é a aplicação de transformações nas imagens (e.g., rotação, alterações de brilho, contraste, zoom, etc.). Esses padrões combinados geram novas amostras únicas que são utilizadas no treinamento da rede neural.

## PROCEDIMENTOS METODOLÓGICOS

Neste trabalho utilizou-se a base de dados disponibilizada por Esgario, Krohling e Ventura (2018) através do GitHub<sup>5</sup>. Os autores disponibilizaram duas bases de dados, mas para este trabalho foi utilizada apenas a base de recortes de folhas. Os resultados foram comparados com outros trabalhos da literatura que também utilizaram a mesma base de dados.

Na base original, as imagens das folhas passaram por um processo de recorte manual de regiões de interesse, onde haviam partes saudáveis e doentes. O conjunto de dados de recortes de folhas compreende um total de 2.721 imagens, distribuídas em cinco classes distintas: uma referente a folhas saudáveis e as demais relacionadas a quatro tipos diferentes de doenças. Contudo, neste estudo, o foco será apenas em dois tipos de doenças: bicho-mineiro e ferrugem. O motivo dessa escolha se deve ao fato de sua ocorrência em território brasileiro e de serem encontradas com muita frequência em trabalhos acadêmicos. Dessa forma, a base utilizada foi reduzida para um total de 1.839 imagens. Desse total, 255 imagens são recortes de folhas saudáveis, 593 são afetadas pelo bicho-mineiro e 991 exibem sintomas da doença ferrugem.

Todas as imagens dessa base estão no formato JPEG e se baseiam no canal de cores RGB, composto pelas três cores primárias. As dimensões das imagens variam bastante, com exemplos como 56x58, 241x237, 402x119 e 412x498. A imagem que detém a menor área tem dimensões de 15x18, enquanto a de maior área mede 561x550 pixels. Analisando a altura e a largura de todas as imagens originais, a menor altura encontrada foi de 15 pixels, a menor largura de 16 pixels, a maior altura alcançou 852 pixels e a maior largura, 825 pixels.

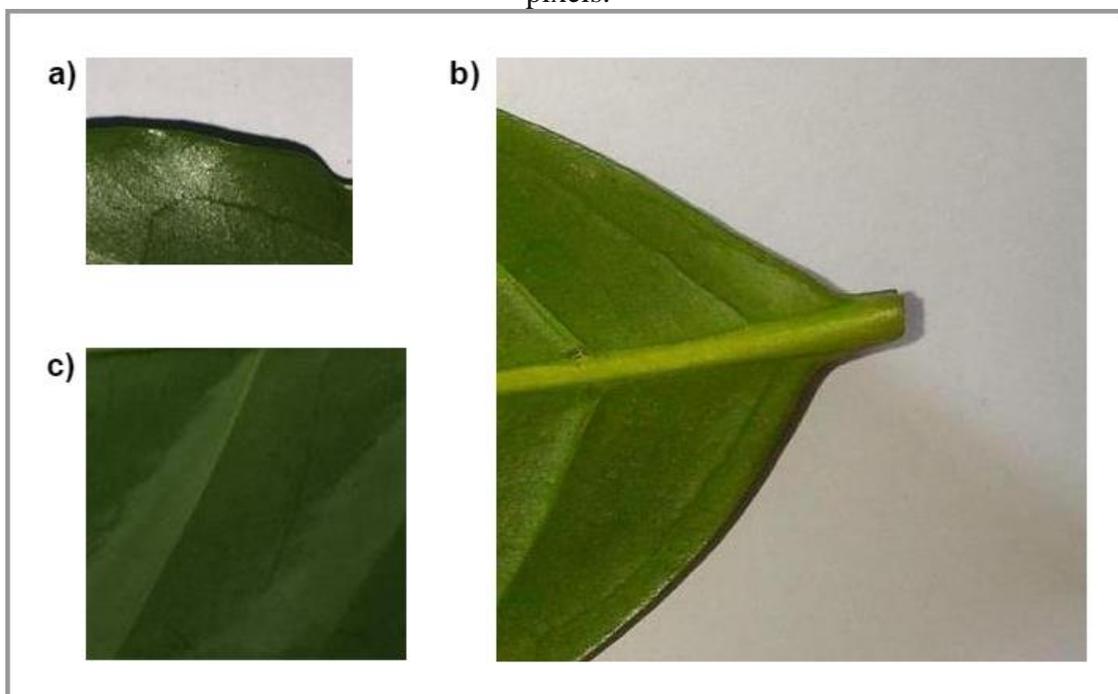
---

<sup>5</sup><https://github.com/esgario/lara2018/tree/master/classification/dataset>

Os recortes de folhas demonstrados nas três próximas imagens possuem dimensões com proporções reais, deixando visível como os modelos de ML conseguem trabalhar com várias resoluções. Fica nítido também que há oscilações na luminosidade sobre as folhas, variações visuais consideráveis mesmo dentre as mesmas doenças e alguns recortes possuem fundos brancos sendo alguns com sombreamentos.

A Imagem 3 ilustra os diferentes recortes de imagens saudáveis, gerando a base de dados de trabalho.

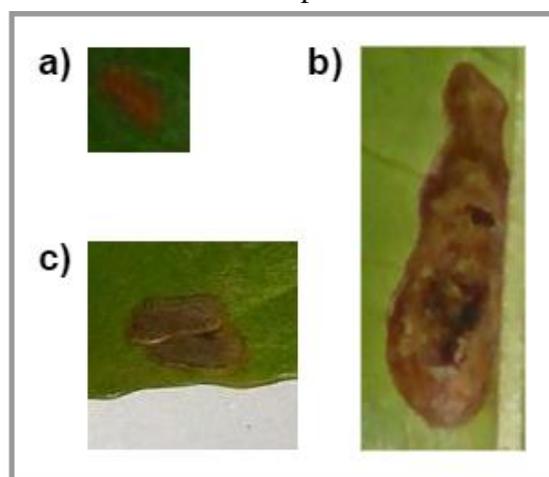
Imagem 3 – Diferentes imagens de folhas saudáveis encontradas na base de dados utilizada. a) imagem com 169x132 pixels; b) imagem com 374x385 pixels; c) imagem com 203x199 pixels.



Fonte: Esgario, Krohling e Ventura, 2018.

A Imagem 4, por outro lado, exhibe diferentes recortes de partes não saudáveis das folhas, atingida pelo bicho mineiro.

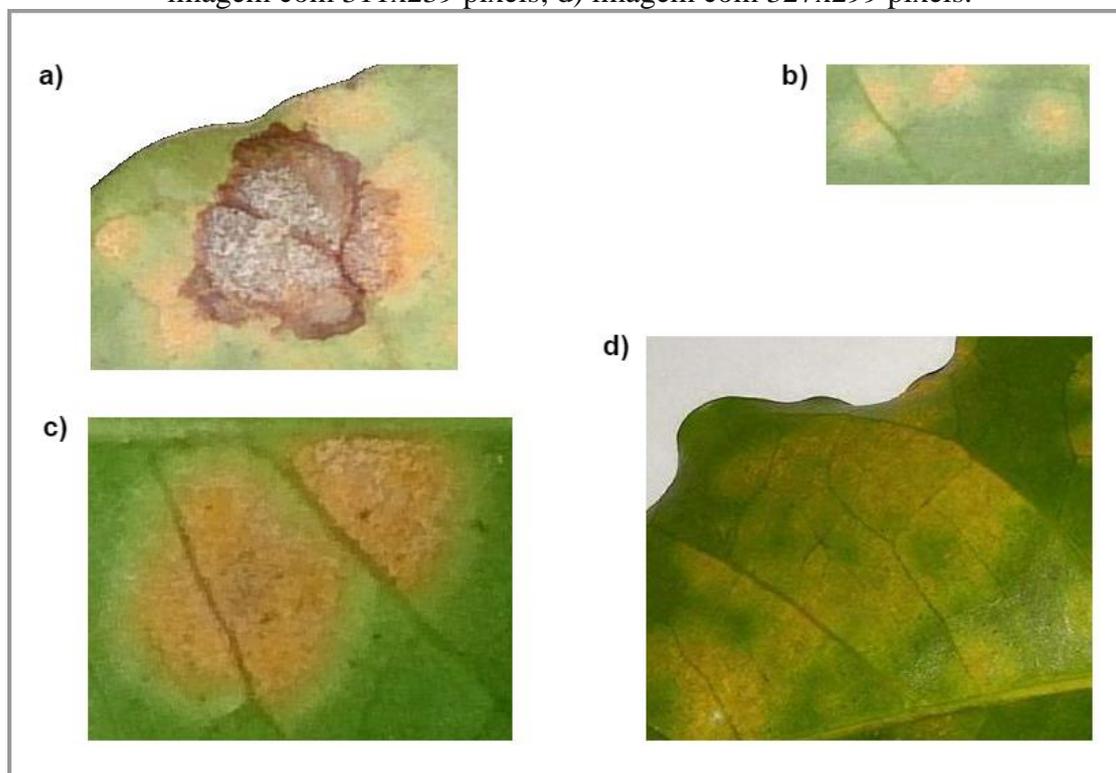
Imagem 4 – Diferentes recortes de folhas afetadas pelo bicho-mineiro encontradas na base de dados utilizada. a) imagem com 56x58 pixels; b) imagem com 115x115 pixels; c) imagem com 223x90 pixels.



Fonte: Esgario, Krohling e Ventura, 2018.

E a Imagem 5, por fim, demonstra pedaços de folhas atingidas pela ferrugem.

Imagem 5 – Diferentes recortes de folhas afetadas pela ferrugem encontradas na base de dados utilizada. a) imagem com 269x226 pixels; b) imagem com 193x89 pixels; c) imagem com 311x239 pixels; d) imagem com 327x299 pixels.

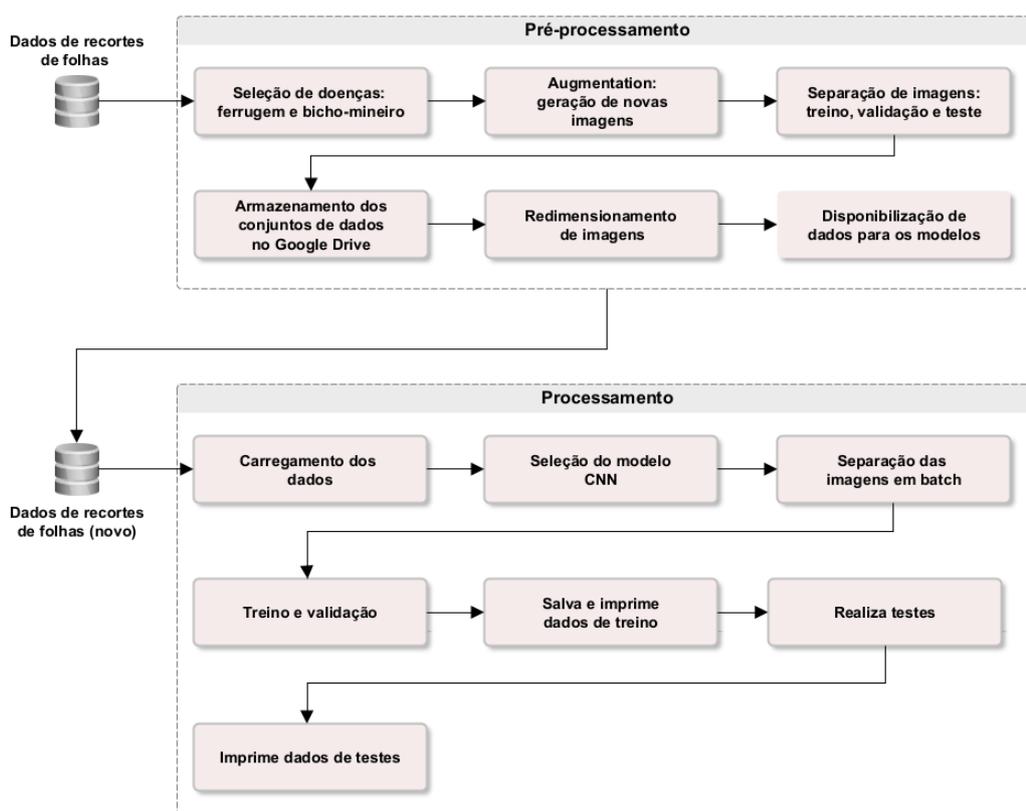


Fonte: Esgario, Krohling e Ventura, 2018.

Após a confecção da base de dados, tem-se início a fase de pré-processamento (Imagem 6). Nesse estágio se encontra a etapa de *data augmentation*, a separação do conjunto de dados em treino, validação e teste, o armazenamento dos dados no Google Drive, o redimensionamento das imagens e, finalmente, a disponibilização dos dados para os modelos.

Para o processo de *data augmentation*, foi estabelecido um limiar de 1.000 amostras (recortes de folhas) para cada classe (saudável, bicho-mineiro e ferrugem). Um número significativamente menor poderia levar o algoritmo a um super ajuste (*overfitting*). Por outro lado, um número muito acima de 1.000 amostras poderia exigir um aumento nas transformações, resultando em imagens excessivamente similares ou distorcidas, aumentando também o tempo de treinamento dos algoritmos. Assim, foram geradas e adicionadas ao *dataset* original 745 novas imagens de folhas saudáveis, 407 novas imagens de bicho-mineiro e apenas 9 novas imagens representando a ferrugem.

Imagem 6 – Fluxograma da abordagem proposta neste trabalho.

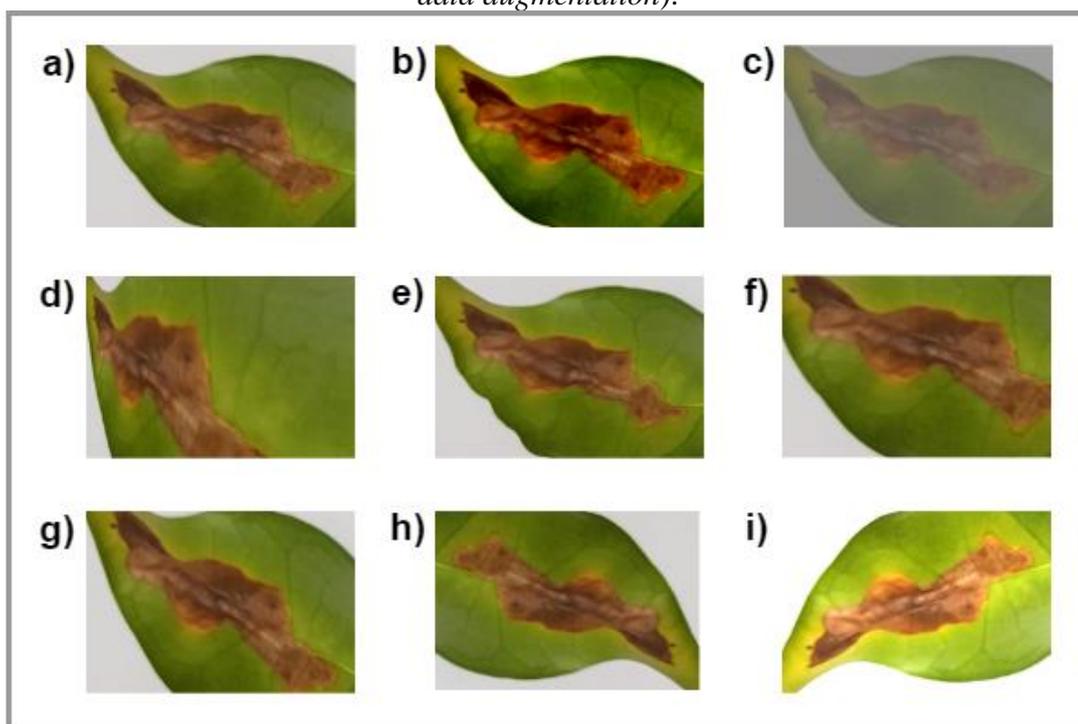


Elaboração: Do autor, 2023.

Os parâmetros das transformações foram definidos de forma empírica. A Imagem 7 mostra as técnicas aplicadas sobre o mesmo recorte de folha original (a), que são: (b) e (c) são

transformações com diferentes contrastes; (d) simula a perspectiva de um observador posicionado mais a direita da figura; (e) foi aplicada distorção gaussiana trazendo algumas deformações; (f) houve um zoom sobre o sintoma; (g) representa remoção das bordas da imagem; e em (h) foi realizada uma rotação de 180° sobre o eixo  $x$  da figura. Apesar das transformações terem sido demonstradas separadamente para facilitar a visualização do leitor, na prática elas foram aplicadas em conjunto, sendo definidas pelo algoritmo aleatoriamente com base em probabilidades parametrizadas, conforme é exemplificado em (i), onde houve aumento do brilho e rotação de 180° sobre o eixo  $y$ . Desse modo, é possível gerar novas imagens simulando diferentes formatos, luminosidades e contrastes, e posicionamento da câmera e do alvo. A nova base de dados, que inclui as adições de imagens modificadas, está disponível no Github<sup>6</sup>.

Imagem 7 – Exemplos de transformações aplicadas sobre uma imagem (para compor a *data augmentation*).



Elaboração: Do autor, 2023.

Foram comparados quatro modelos distintos de *Deep Learnings*: Sequential (CHOLLET, 2020), Resnet50 (HE et al., 2016), Xception (CHOLLET, 2017) e VGG16 (SIMONYAN; ZISSERMAN, 2014). O modelo Sequential foi completamente configurado e

<sup>6</sup><https://github.com/charlyBraga/pre-processed-diseases-coffee-leaves-images/tree/main>

treinado desde o início, sem utilizar modelos preexistentes. O Xception é pré-configurado, possuindo uma estrutura de camadas previamente estabelecida. Resnet50 e VGG16, além de serem pré-configurados, também são pré-treinados, com parâmetros ajustados em base de treinamentos anteriores, com imagens disponibilizadas por Stanford Vision Lab (2021).

Foi utilizado também o método de *Early Stopping* (ES), onde o treinamento é forçado a parar quando a medida utilizada não consegue apresentar melhorias ao progresso das iterações de treinamento (Goodfellow et al., 2016).

O processo de treinamento das quatro redes está detalhado na Tabela 1. A Resnet50 teve o maior número de épocas, enquanto a Sequential teve o menor. Todas foram configuradas para rodar por 60 iterações. No entanto, implementou-se a estratégia de *Early Stopping*, que encerra o treinamento se a CNN ficar por 10 épocas consecutivas sem aprendizado, recuperando, assim, o melhor resultado alcançado até o momento.

Tabela 1 – Configurações das CNNs.

CNN	Iterações	<i>Early Stopping</i>	Taxa de aprendizado inicial	<i>Step Decay</i>	<i>Batch</i>	Otimizador	Dimensões de entrada
Sequential	12	10	0,0001	0,5/7	64	Adam	300x300x3
Resnet50	24	10	0,0001	0,5/7	64	Adam	300x300x3
Xception	16	10	0,0001	0,5/7	64	Adam	300x300x3
VGG16	14	10	0,0001	0,5/7	32	Adam	300x300x3

Elaboração: Do autor, 2023.

A taxa de aprendizado inicial foi estabelecida em 0,0001 para todos os modelos. Para acelerar o aprendizado nas fases iniciais do treino e torná-lo mais suave posteriormente, configurou-se o parâmetro *Step Decay*, que permite iniciar com essa taxa e reduzir seu valor pela metade a cada 7 épocas.

Os valores de configuração foram estabelecidos empiricamente, com base nos resultados obtidos, avaliando vários índices, como acurácia, erro, precisão e sensibilidade, além da análise dos gráficos de erro de treino e validação.

Outros valores para os parâmetros incluem: iteração com valores fixos de 25, 50, 100, 200 e 400; *Early Stopping* com 5 e 10 épocas; taxa de aprendizado (fixa ou com *Step Decay*)

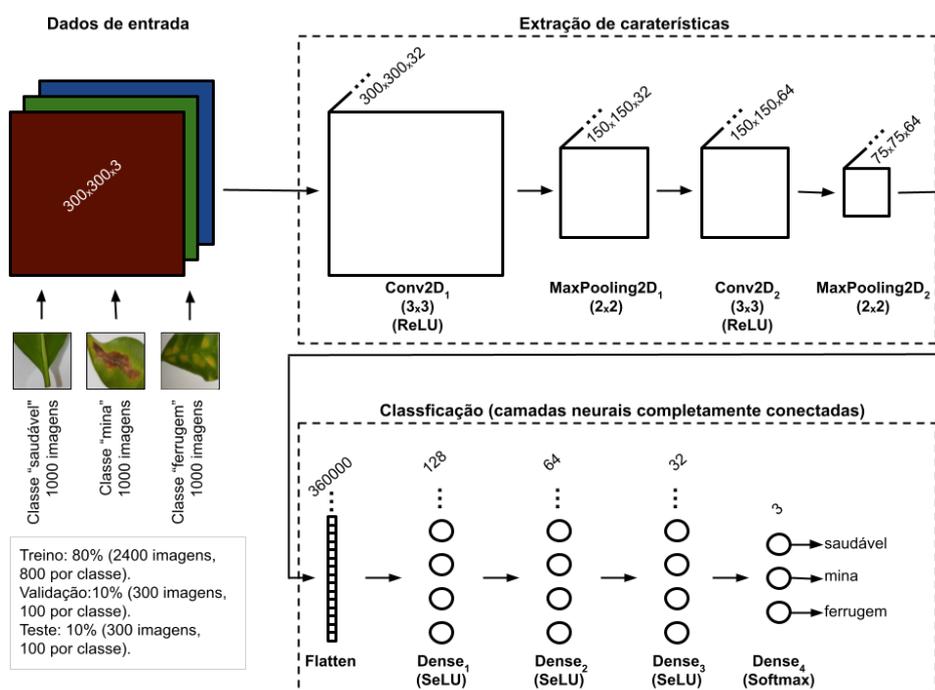
com valores entre 0,1 e 0,000001, variando em potência de 10; *Step Decay* apenas 0,5/7; *batch* de 32, 64 e 128; otimizador Adam, RMSprop e SGD; e dimensões de entrada com 128x128x3, 224x224x3, 256x256x3, 300x300x3, 400x400x3 e 512x512x3.

Outro parâmetro denominado *Shuffle* é utilizado para que a rede embaralhe os dados provenientes do diretório a cada época. Esse procedimento ajuda a prevenir que o modelo aprenda padrões não intencionais decorrentes da ordem das amostras, mitigando assim o risco de *overfitting*. O *Shuffle* foi aplicado somente durante o treinamento e não foi utilizado durante a validação e os testes.

Para assegurar que a cada execução do programa os dados sejam sempre embaralhados da mesma maneira, foi estabelecido um atributo chamado *Seed*, configurado com o valor 1. Dessa forma, garante-se que os dados sejam sempre embaralhados de forma consistente, para não beneficiar nenhum modelo. Mesmo com esse embaralhamento padrão, o uso do *Shuffle* é fundamental para evitar que o modelo identifique padrões decorrentes da ordem dos dados.

A Imagem 8 ilustra os passos da rede CNN Sequencial proposta. A arquitetura é composta de duas regiões principais, sendo a primeira onde é feito o processo convolucional, que tem o objetivo de extrair das imagens apenas as características julgadas importantes pela rede. E a segunda região é onde ocorre a classificação utilizando RNA.

Imagem 8 – Etapas e configuração da Rede Neural Sequencial proposta.



Elaboração: Do autor, 2023.

O processo começa com imagens de entrada, que podem ser da classe “saudável”, “mina” ou “ferrugem”, tendo dimensões de 300x300x3 pixels, sendo 300 em altura e largura, e 3 em profundidade, correspondendo aos canais de cores, este último número. A imagem RGB entra na região de extração de características, passando inicialmente pela camada convolucional denominada Conv2D<sub>1</sub>, que possui filtro 3x3, função de ativação ReLU e cuja saída é uma imagem de 300x300x32 pixels. A saída dessa camada da rede mantém a mesma largura e altura da imagem original de entrada, porém, o que muda é que agora há 32 níveis de profundidade.

Em seguida, tem-se a camada MaxPooling2D<sub>1</sub> com filtro 2x2, que recebe os dados de Conv2D<sub>1</sub> e os converte para as dimensões de 150x150x32 pixels. Neste ponto, a imagem possui metade da altura e largura originais, mas mantém uma profundidade de 32.

A seguir, a imagem é submetida à outra convolução (Conv2D<sub>2</sub>) e, posteriormente, a um *pooling* (MaxPooling2D<sub>2</sub>) com as mesmas configurações do anterior, resultando em uma imagem com dimensões de 75x75x64 pixels. A imagem tem sua largura e altura reduzidas pela metade da imagem anterior. Finaliza-se o processo de extração de características.

No Flatten, agora já dentro da região da classificação, a matriz tridimensional oriunda de MaxPooling2D<sub>2</sub> da região anterior é transformada em um vetor com 360.000 posições para se tornar adequada à entrada da rede neural. A seguir, há quatro camadas de redes neurais denominadas Dense, cujas saídas são de 128, 64, 32 e 3, respectivamente, sendo que o último número representa a quantidade de classes. As saídas destas camadas correspondem ao número de neurônios em cada uma. As três primeiras camadas empregam a função de ativação SeLU por questão de estabilização, enquanto a última camada utiliza Softmax para calcular as probabilidades das três classes.

De forma resumida, uma imagem é inserida, podendo pertencer a uma das três classes. Ela passa pela região de extração de características, em seguida pela região de classificação, e por fim a rede indica a probabilidade da imagem de entrada pertencer à classe “saudável”, “mina” ou “ferrugem”.

Além desse modelo de rede neural discutido, também foram utilizados o Resnet50, o Xception e o VGG16, que já vieram pré-treinados e/ou pré-configurados.

A Resnet50 é composta por diversas camadas de diferentes tipos. A única modificação feita na estrutura original da Resnet50 foi a inclusão de uma camada Dense com 128 neurônios antes da camada final, utilizando a função de ativação SeLU. Essa alteração resultou em uma melhoria na acurácia do modelo.

O modelo Xception, ao contrário da Resnet50, não vem pré-treinado, mas já possui uma estrutura de camadas pré-configurada. Em um processo similar ao realizado com a Resnet50, foi adicionada uma camada Dense com 128 neurônios, imediatamente antes da camada final. Esta alteração foi decidida empiricamente, gerando melhores resultados.

A CNN VGG16, assim como a Resnet50, é pré-configurada e pré-treinada. Semelhantemente à Resnet50 e Xception, a VGG16 teve uma camada Dense inserida imediatamente antes da camada final. No entanto, a diferença é que esta camada possui 512 neurônios, uma modificação que resultou em melhor acurácia.

## RESULTADOS E DISCUSSÕES

A Tabela 2 apresenta o resultado dos quatro modelos utilizados na identificação das três classes: (1) saudável, (2) bicho-mineiro ou (3) ferrugem, considerando diferentes índices comumente utilizados no aprendizado de máquina. É possível observar que a Resnet50 atingiu a melhor acurácia, seguido pelo modelo Sequential proposto. O tempo de treinamento também ficou bastante próximo em todos os casos.

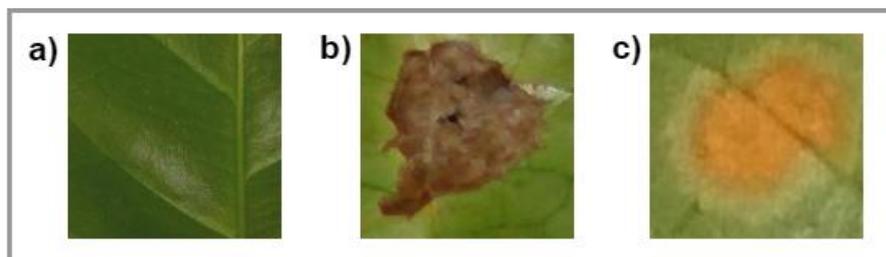
Tabela 2 – Índices obtidos pelas quatro diferentes CNNs propostas neste trabalho.

CNN	Acurácia(%)	Erro	AUC(%)	Prec(%)	Sens(%)	VP	FP	Treino (min)
Resnet50	99,67	0,0231	99,97	99,67	99,67	299	1	2,12
Sequential	98,33	0,0766	99,69	98,36	98,33	295	5	2,37
Xception	98,00	0,1029	99,66	98,00	98,00	294	6	2,41
VGG16	97,00	0,1047	99,38	97,03	97,00	291	9	3,17

Elaboração: Do autor, 2023.

Na Imagem 9, são exibidos exemplos em que os modelos propostos neste trabalho acertaram. A primeira imagem (a) representa a classe “saudável”. Apesar de a imagem apresentar focos de luz, isso não confundiu a rede, que não a interpretou como sintoma de ferrugem. Isso é possivelmente devido à diferença nas características: enquanto o sintoma de ferrugem é amarelo e arredondado, o foco de luz é branco e alongado. Na imagem (b), tem-se a classe “mina”, caracterizada pela cor marrom e formatos variados. E, por fim, na imagem (c), é ilustrada a classe “ferrugem”.

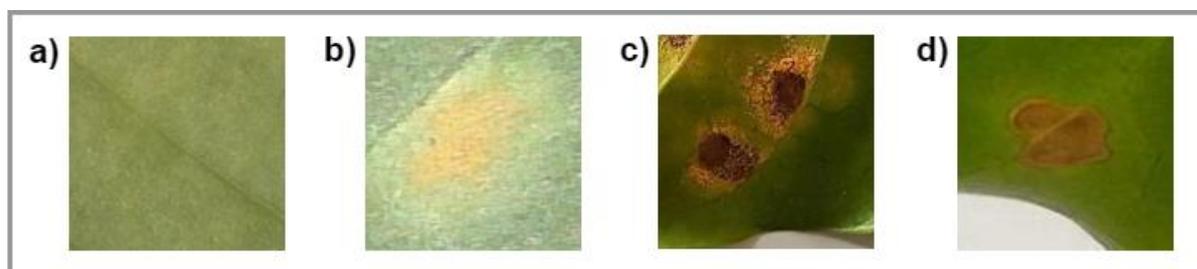
Imagem 9 – Exemplos de acertos cometidos pelas as redes durante a predição.



Elaboração: Do autor, 2023.

A Imagem 10 exibe os erros mais comuns cometidos pelos quatro modelos de CNN propostos neste trabalho. A primeira imagem (a), que representa a classe “saudável”, foi erroneamente predita como “ferrugem”. O possível fator que levou o modelo a cometer este erro pode ser a presença de algumas manchas claras na folha. Na segunda imagem (b), cuja classe correta é “ferrugem”, a previsão foi “saudável”. Isso pode ter ocorrido devido à sutileza da mancha amarela, que pode ter sido confundida pela rede com um mero foco de luminosidade em uma folha saudável. A terceira imagem (c) representa a classe “ferrugem”, mas foi incorretamente classificada como “mina”. A presença de necrose na folha torna extremamente desafiador para a rede distinguir entre os sintomas de ferrugem e de bichomineiro, sendo este o erro mais recorrente. Por fim, na imagem (d), que pertence à classe “mina”, ocorreu uma classificação equivocada para “ferrugem”. O formato arredondado do sintoma, que se assemelha ao da ferrugem, aliado à coloração marrom clara, pode ter induzido ao erro.

Imagem 10 – Exemplos de erros comuns cometidos pelas as redes durante a predição.

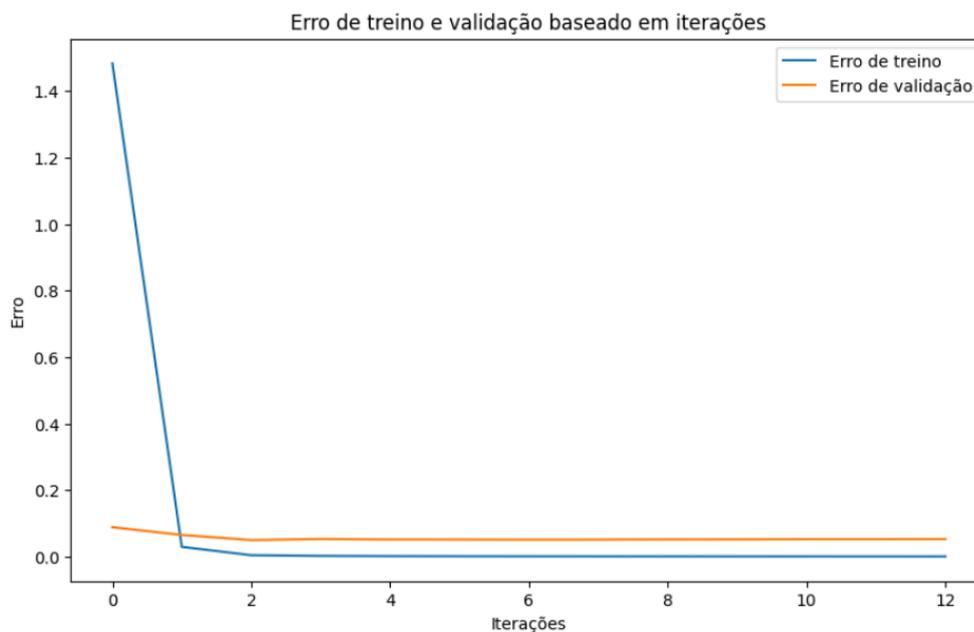


Elaboração: Do autor, 2023.

Em relação ao processo de predição da Resnet50, que obteve o melhor desempenho na acurácia, a Imagem 11 ilustra a queda do gradiente na busca pelo menor erro. A linha azul, correspondente ao treino, indica que a rede aprende de forma acelerada. Já na primeira época de treino, ela consegue se aproximar significativamente do valor zero. Pequenos ajustes nos

pesos sinápticos da rede ocorrem entre as épocas 1 e 2. Após isso, a rede estabiliza, indicando uma parada no aprendizado.

Imagem 11 – Erro de treino e validação da Resnet50.

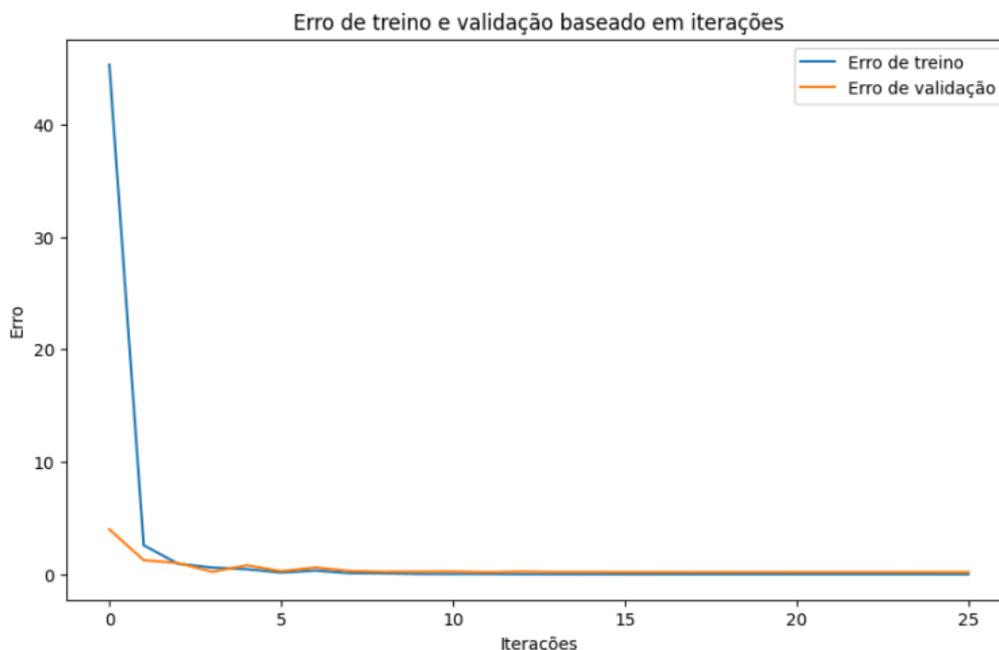


Elaboração: Do autor, 2023.

Por sua vez, a linha laranja, que representa a validação, tem um comportamento de queda até a segunda época, assim como a linha de treino, e posteriormente também se estabiliza. A técnica de *Early Stopping* permite que a rede tente otimizar sua performance por 10 épocas, retomando sempre a melhor performance obtida. É relevante destacar que a rede demonstrou uma capacidade de aprendizado rápido, e as duas linhas exibem padrões similares com uma distância entre elas relativamente pequena. Além disso, em nenhum momento o erro da validação apresenta aumento, o que não indica a possível ocorrência de *overfitting*. As linhas são consistentes e não mostram oscilações ou instabilidades, evitando assim a sugestão de potenciais problemas na arquitetura da rede ou no conjunto de dados.

O gráfico de erro apresentado na Imagem 12 é referente ao modelo Sequential, que alcançou a segunda melhor acurácia, é possível observar que o modelo aprende de forma rápida já na primeira época e continua aprimorando até a 7ª iteração. Embora a linha de validação exiba uma leve oscilação durante os ajustes dos pesos sinápticos, ela se estabiliza e quase se sobrepõe à linha azul, que representa o treino, indicando uma boa validação.

Imagem 12 – Erro de treino e validação do modelo Sequential.



Elaboração: Do autor, 2023.

Por fim, foram utilizados alguns dos principais índices da literatura para comparar este trabalho com outros. A Tabela 3 ilustra os índices obtidos neste trabalhado quando comparado com os outros trabalhos da literatura que propuseram abordagens utilizando a mesma base de dados. O trabalho aqui proposto foi capaz de melhorar os índices de acurácia existentes na literatura, que se traduz diretamente em quantidade de imagens corretamente classificadas.

As duas redes com melhor desempenho neste trabalho, Resnet50 e Sequential, foram comparadas aos melhores resultados de outros três trabalhos que utilizam a mesma base de dados. Conforme demonstrado na Tabela 3, a Resnet50 deste trabalho obteve a melhor acurácia, menor erro, melhor precisão e melhor sensibilidade, o que está destacado em negrito. O modelo Sequential deste trabalho obteve o segundo melhor resultado, seguido pelos trabalhos de Kumar *et al.* (2020), Esgario *et al.*(2021) e Esgario, Krohling e Ventura (2020). A coluna “VP” (Verdadeiro Positivo) demonstra o total de imagens que foram preditas corretamente e a “FP” (Falso Positivo) contém a quantidade de erros de predição.

Tabela 3 – Desempenhos dos trabalhos que utilizaram a mesma base de dados.

Autores	Acurácia (%)	Erro	Precisão (%)	Sensibilidade (%)	VP	FP
Do autor (Resnet50)	<b>99,67</b>	<b>0,0231</b>	<b>99,67</b>	<b>99,67</b>	<b>299</b>	<b>1</b>
Do autor (Sequential)	98,33	0,0766	98,36	98,33	295	5
Kumar et al. (2020)	97,61	0,35	-	-	327	8
Esgario, Krohling e Ventura (2020)	95,63	0,0437	94,14	92,32	241	11
Esgario et al.(2021)	97,07	0,0293	96,85	96,69	397	12

**Elaboração:** Do autor, 2023.

A Tabela 4 apresenta algumas importantes características dos trabalhos que tiveram seus desempenhos exibidos na Tabela 3. Todos os estudos mencionados utilizaram a CNN ResNet50, com exceção de Kumar *et al.* (2020), que utilizou a CNN InceptionV3. Metade dos trabalhos utilizou a biblioteca TensorFlow, criada pelo Google, enquanto a outra metade empregou a PyTorch, desenvolvida pela Meta. Ambas as bibliotecas são de código aberto, com suporte à linguagem de programação Python, e são robustas para atender às necessidades na área de Inteligência Artificial. No entanto, a decisão de utilizar a TensorFlow neste trabalho foi devido à familiaridade prévia.

A rede implementada neste trabalho foi a única a utilizar a técnica de regularização *Early Stopping* para interromper o treinamento ao detectar *overfitting*, recuperando o último melhor resultado. Todos os outros trabalhos utilizaram somente arquiteturas de CNN pré-treinadas, com exceção do Sequential, que teve uma CNN construída sem utilizar modelos preexistentes.

O gráfico de erro, conforme apresentado na Imagem 12, é fundamental para compreender o processo de treinamento e identificar possíveis problemas, como a ocorrência de *overfitting*. Assim, na Tabela 4, apenas este estudo e o de Kumar *et al.* (2020) apresentaram o gráfico mencionado.

Como este estudo possui uma base de dados relativamente grande, com 3.000 amostras, foi possível dividir o treino, validação e testes nas proporções de 80%, 10% e 10%, respectivamente. Já os outros trabalhos utilizaram as proporções de 75%, 15% e 15%, não informando a quantidade de amostras dos respectivos conjuntos de dados após o processo de *data augmentation*.

Tabela 4 – CNNs de quatro diferentes estudos que utilizam a mesma fonte de dados.

Comparações	Do autor	Kumar <i>et al.</i> (2020)	Esgario, Krohling e Ventura (2020)	Esgario <i>et al.</i> (2021)
Melhor técnica de ML por estudo	ResNet50	InceptionV3	ResNet50	ResNet50
Biblioteca de ML	TensorFlow	TensorFlow	PyTorch	PyTorch
Otimizador	ADAM	MBGD	SGD	SGD
Usa <i>Early Stopping</i>	Sim	Não	Não	Não
Usa construção de CNN a partir da base	Sim	Não	Não	Não
Exibe gráfico de erro do aprendizado	Sim	Sim	Não	Não
Divisão treino, validação e teste (%)	80-10-10	70-15-15	75-15-15	75-15-15
Nº de épocas	12	12	100	100
Nº de classes	3	5	5	5
Usa <i>data augmentation</i>	Sim	Sim	Sim	Sim
Nº de imagens totais após <i>data augmentation</i>	3000	-	-	-
Data augmentation definida manualmente	Sim	Não	Não	Não
Nº de tipos de transformações para <i>data augmentation</i>	8	-	6	-
Há balanceamento de classes de dados	Sim	Não	Não	Não
Limpeza de dados	Remoção de alguns fundos pretos	Eliminação de ruídos e realçamentos de sintomas	-	Segmentação realçamentos de sintomas
Dimensão final das imagens (pixels)	300x300x3	299x299x3	224x224x3	299x299x3

Elaboração: Do autor, 2024.

Uma vantagem deste trabalho e de Kumar *et al.* (2020) em relação ao processamento é que foram necessárias apenas 12 épocas para treinar as redes neurais, enquanto os outros trabalhos gastaram 100 épocas.

Uma limitação deste estudo reside na utilização de apenas três classes de dados: folhas saudáveis, com ferrugem e com minas. Essa escolha foi motivada pelos objetivos específicos

desta pesquisa. Todos os outros estudos utilizaram cinco classes, o que, embora aumente a complexidade da classificação, pode resultar em modelos mais robustos.

Diferentemente dos outros trabalhos, que empregaram técnicas automáticas de *data augmentation* em tempo real, este estudo optou por realizar manualmente as transformações nas imagens. Essa abordagem permitiu um controle mais preciso sobre a qualidade das figuras geradas, garantindo que apenas aquelas com características visuais satisfatórias fossem incluídas no conjunto de dados. Além disso, a inspeção visual possibilitou balancear a quantidade de amostras por classe, evitando vieses no treinamento do modelo. Embora a abordagem manual seja mais trabalhosa e exija mais tempo, os resultados obtidos indicam que ela contribuiu para melhorar a precisão do modelo de classificação, especialmente para as classes minoritárias.

A penúltima linha da Tabela 4 apresenta a limpeza de dados realizada em cada pesquisa. Neste trabalho, foi necessária a remoção de fundos pretos em algumas imagens para padronizar a base de dados, tornando-os brancos como na maioria dos casos. Essa etapa foi crucial para melhorar a segmentação das regiões de interesse.

Por fim, a última linha da mesma tabela indica as dimensões das imagens utilizadas em cada estudo. Neste trabalho, as dimensões 300x300x3 pixels foram definidas empiricamente, após diversos testes, por apresentarem os melhores resultados nas CNNs. Todas as amostras do conjunto de dados foram padronizadas com as mesmas dimensões, devido ao padrão de entrada das redes neurais.

## CONSIDERAÇÕES FINAIS

Neste trabalho foi proposto uma melhoria no processo de classificação automática de folhas de café, com o objetivo de identificar três possíveis classes: “saudável”, “mina” e “ferrugem”. O *framework* proposto obteve uma melhoria na acurácia de 2,06% relacionada ao problema, em comparação com todos os outros trabalhos da literatura. Apesar da melhoria, precisa-se ser levado em consideração vantagens deste trabalho, como classes balanceadas e transformações de imagens controladas, e desvantagem como maior facilidade de classificação por conter menos classes de dados.

O processo de modelagem incluiu um aumento da base de dados, com operações de transformação de imagens idealizadas especificamente para o problema das folhas de café. Isso, agregado à extensiva avaliação de diferentes redes neurais convolucionais, associados à

boas escolhas de parâmetro e treinamento das mesmas, forneceu a melhoria na acurácia descrita neste trabalho.

Além disso, foi feito um levantamento bibliográfico exaustivo e selecionamos os trabalhos os principais trabalhos na literatura sobre o tema de classificação de folhas de café, que é bastante recente, e de interesse ao Brasil pela extensa produção e exportação de café. Acredita-se que uma melhor identificação automática dessas doenças possa levar a melhorar a produtividade, tentando prever e evitar com que as pragas aconteçam.

O fato de produzir uma abordagem computacional para a classificação também possibilita a automatização padronizada da tarefa de identificação. Por exemplo, é possível existir casos que um usuário classifique certa folha como ferrugem e outro usuário, utilizando os mesmos princípios, classifique a mesma imagem como saudável. Ao automatizar o processo de forma computacional, conseguimos manter uma padronização na classificação, onde uma folha em específico sempre terá uma mesma classe associada.

Trabalhos futuros incluem a possibilidade de automatizar ainda outros pontos que por enquanto não estão sendo automatizados como, por exemplo, a coleta das imagens das folhas. Idealmente, é possível tentar coletar essas imagens com um drone, de forma automática, e posteriormente aplicar a abordagem descrita neste trabalho. Pelo fato da tarefa de coleta ser extremamente complexa por si só, deixa-se essa abordagem para um trabalho futuro.

## REFERÊNCIAS

BARBEDO, J. G. A. Plant disease identification from individual lesions and spots using deep learning. **Biosystems Engineering**, v. 180, p. 96–107, 2019.

CABALLERO, E. M. T.; DUKE, A. M. R. Implementation of artificial neural networks using nvidia digits and opencv for coffee rust detection. In: **2020 5th International Conference on Control and Robotics Engineering (ICCRE)**. [S.l.: s.n.], 2020. p. 246–251.

CARNEIRO, A. L. C.; SILVA, L. de B.; FAULIN, M. S. A. R. **Artificial intelligence for detection and quantification of rust and leaf miner in coffee crop**. 2021.

CASTILLO, G. **O bicho mineiro e os métodos de controle dessa praga tão devastadora**. 2016. Disponível em: <https://3rlab.wordpress.com/2016/06/01/o-bicho-mineiro-e-os-metodos-decontrole-dessa-praga-tao-devastadora/>. Acesso em: 05 nov. 2023.

CASTRO, W. et al. Evaluation of expert systems techniques for classifying different stages of coffee rust infection in hyperspectral images. **International Journal of Computational Intelligence Systems**, v. 11, p. 86–100, 2018. DOI: <https://doi.org/10.2991/ijcis.11.1.8>.

CHEMURA, A.; MUTANGA, O.; SIBANDA, M. e. a. Machine learning prediction of coffee rust severity on leaves using spectroradiometer data. **Int J Biometeorol** **64**, p. 671–688, 2018.

CHOLLET, F. Xception: Deep learning with depthwise separable convolutions. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. [S.l.: s.n.], 2017. p. 1251–1258.

CHOLLET, F. **The Sequential Model**. 2020. Keras Documentation. 2020.

CONCEIÇÃO, C. H. C.; GUERREIRO-FILHO, O.; GONÇALVES, W. Flutuação populacional do bicho-mineiro em cultivares. **Bragantia**, v. 64, n. 4, p. 625–631, 2005. Disponível em: [https://keras.io/guides/sequential\\_model](https://keras.io/guides/sequential_model). Acesso em: 11 nov. 2023.

DANTAS, J. et al. A comprehensive review of the coffee leaf miner *leucoptera coffeella* (lepidoptera: Lyonetiidae), with special regard to neotropical impacts, pest management and control. **Preprints**, v. 2020100629, 2020.

DONG, S.; WANG, P.; ABBAS, K. A survey on deep learning and its applications. **Computer Science Review**, v. 40, p. 100379, 2021. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1574013721000198>. Acesso em: 16 out. 2023.

EMBRAPA. **Relatório mensal - dezembro 2020**. 2021. Cecafe - Conselho dos Exportadores de Café. Anísio José Diniz, Lucas Tadeu Ferreira. Embrapa Café. Disponível em: <https://www.embrapa.br/busca-de-noticias/-/noticia/58841714/exportacoes-dos-cafes-do-brasil-somam-445-milhoes-de-sacas-em-2020-e-batem-recorde-historico>. Acesso em: 11/01/2022.

EMBRAPA. **Relatório sobre o mercado de café - abril 2023**. 2023. Cecafe - Conselho dos Exportadores de Café. Anísio José Diniz, Lucas Tadeu Ferreira. Embrapa Café. Disponível em: <https://www.embrapa.br/busca-de-noticias/-/noticia/80815479/producao-mundial-de-cafe-foi-estimada-em-1713-milhoes-de-sacas-de-60kg-para-safra-2022-2023>. Acesso em: 12/09/2023.

ESGARIO, J. G.; KROHLING, R. A.; VENTURA, J. A. **Base de dados de folhas de Café**. 2018. Ano de Criação: 2018. Disponível em: <https://github.com/esgario/lara2018/tree/master/classification/dataset>. Acesso em: 01 abr. 2023.

ESGARIO, J. G.; KROHLING, R. A.; VENTURA, J. A. Deep learning for classification and severity estimation of coffee leaf biotic stress. **Computers and Electronics in Agriculture**, v. 169, p. 105162, 2020. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169919313225>. Acesso em: 01 abr. 2021.

ESGARIO, J. G. *et al.* An app to assist farmers in the identification of diseases and pests of coffee leaves using deep learning. **Information Processing in Agriculture**, 2021. ISSN 2214-3173. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2214317321000044>. Acesso em: 02/03/2021.

FACELI, K. *et al.* **Inteligência artificial: uma abordagem de aprendizado de máquina.** [S.l.]: LTC, 2021.

HE, K. *et al.* Deep residual learning for image recognition. In: Proceedings of the IEEE conference on computer vision and pattern recognition. [S.l.:s.n.], 2016. p. 770–778.

KUMAR, M. *et al.* Disease detection in coffee plants using convolutional neural network. In: **2020 5th International Conference on Communication and Electronics Systems (ICCES).** [S.l.: s.n.], 2020. p. 755–760.

MANSO, G. L. *et al.* A smartphone application to detection and classification of coffee leaf miner and coffee leaf rust. **CoRR**, abs/1904.00742, 2019. Disponível em: <http://arxiv.org/abs/1904.00742>. Acesso em: 01 mar. 2021.

MARCOS, A. P.; RODOVALHO, N. L. S.; BACKES, A. R. Coffee leaf rust detection using convolutional neural network. In: **2019 XV Workshop de Visão Computacional (WVC).** [S.l.: s.n.], 2019. p. 38–42.

MENDONÇA, T. F. N. de. **Controle de Bicho-Mineiro com Nematoides Entomopatogênicos e Uso de Imagens para Detecção de Minas.** Dissertação (Mestrado) — Universidade Federal de Uberlândia, Monte Carmelo, MG, Brazil, 2021.

MONTALBO, F. J.; HERNANDEZ, A. An optimized classification model for coffea liberica disease using deep convolutional neural networks. In: **Proceedings of the Conference Name.** [S.l.: s.n.], 2020. p. 213–218.

MOURA, K. E. *et al.* Desenvolvimento de um sistema especialista para o diagnóstico de doenças e pragas do cafeeiro. In: **X Simpósio de Pesquisa dos Cafés do Brasil.** Vitória, ES: [s.n.], 2019. Acesso em: 22 de maio 2020. Disponível em: <http://www.consorcioquesquisacafe.com.br/ojs/index.php/SimpósioCafe2019/article/view/439/307>. Acesso em: 03 fev. 2021.

OLIVEIRA, C. *et al.* Crop losses and the economic impact of insect pests on Brazilian agriculture. **Crop Protection**, v. 56, p. 50–54, 02 2014.

SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. **arXiv preprint arXiv:1409.1556**, 2014.

SOARES, W. L. *et al.* Qualidade do café arábica por diferentes granulometrias. **Revista Ciência Agrícola**, 2019. v. 17. 31-35 p. Disponível em: <https://www.seer.ufal.br/index.php/revistacienciaagricola/article/view/6495/5894>. Acesso em: 15 fev. 2021.

Stanford Vision Lab. **ImageNet: An image database organized according to the WordNet hierarchy.** 2021. Online. Disponível em: <https://www.image-net.org/>. Acesso em: 20 out. 2023.

VENTURA, J. A. *et al.* Manejo das doenças do cafeeiro conilon. In. **café conilon.** p.

Página 26 de 27

DOI: <https://doi.org/10.56579/rei.v6i3.972>

435–474, 2017.

VIDAL, L. A. et al. Obtenção de rna de bicho-mineiro (*leucoptera coffeella*) para transcritômica e silenciamento gênico. In: **X Simpósio de Pesquisa dos Cafés do Brasil**. Vitória, ES: [s.n.], 2019. Disponível em: <http://www.consorcioquesquisacafe.com.br/ojs/index.php/SimposioCafe2019/article/view/264/156>. Acesso em: 05/02/2023.

ZAMBOLIM, L. Current status and management of coffee leaf rust in brazil. **Tropical Plant Pathology**, v. 41, n. 1, p. 1–8, 2016. DOI: <https://doi.org/10.1007/s40858-016-0065-9>.