

# Um Comparativo de Abordagens com Redes Neurais Artificiais para Detecção Inteligente de Patologias na Folha do Café

Laís Dib Albuquerque, Elloá B. Guedes

<sup>1</sup>Grupo de Pesquisa em Sistemas Inteligentes  
Universidade do Estado do Amazonas (UEA)  
Av. Darcy Vargas, 1200 – Manaus – Amazonas  
{lda.snf20, ebgcosta}@uea.edu.br

**Abstract.** *This work aimed at evaluating two approaches that make use of Artificial Neural Networks on the problem of automatic classification of coffee leaves diseases on a public domain dataset. Results obtained from computational experiments show efficacy and efficiency of Deep Learning architectures from which ShuffleNet achieved an average  $F_1$ -Score of 99,88 %. The observed performance is equiparable to state-of-art although was obtained both with significantly less parameters and examples. As a consequence, there is a prominent viability for its adoption in Digital Agriculture realistic scenarios.*

**Resumo.** *Este artigo considera duas abordagens para utilização de Redes Neurais Artificiais perante o problema de classificação automática de patologias foliares do café a partir de uma base de dados realística disponível na literatura. Os resultados obtidos através de experimentos computacionais demonstraram a eficácia e eficiência das arquiteturas oriundas da abordagem baseada em Deep Learning, na qual o modelo ShuffleNet obteve  $F_1$ -Score médio igual a 99,88 %, desempenho equiparável ao estado da arte, mas com significativamente menos parâmetros e exposto a menos exemplos, o que enseja sua viabilidade prática enquanto contribuição para Agricultura Digital.*

## 1. Introdução

De acordo com o Ministério da Agricultura, Pecuária e Abastecimento (MAPA), o Brasil consolidou sua posição como um dos maiores produtores e fornecedores de alimentos para o mundo. Além dos fatores naturais, como extensão territorial agricultável e clima propício, menciona-se o investimento em tecnologia e pesquisa como componentes deste bom resultado [MAPA 2019]. Tendo em mente o progresso desse setor, a Agricultura Digital tem se consolidado de maneira expressiva, sendo caracterizada pelo uso e desenvolvimento de soluções tecnológicas relacionadas à área da Informática com o objetivo de melhorar a produção agrícola, obtendo mais qualidade e produtividade [Tang et al. 2002]. No Brasil, em especial, as técnicas de Processamento de Imagem e de Visão Computacional (VC) já figuram explicitamente como componentes integrantes dos eixos estratégicos a serem desenvolvidos e adotados nas próximas duas décadas [Embrapa 2014].

Mais recentemente, a Aprendizagem de Máquina (AM), subárea da Inteligência Artificial que contempla a proposição e utilização de modelos e métodos computacionais capazes de aprender a partir de dados, gerando inferências para instâncias ainda não vistas [Faceli et al. 2021], tem avançado substancialmente o estado da arte em problemas de VC [Khan et al. 2018]. Esses resultados impactam positivamente no desenvolvimento de soluções para a Agricultura, tais como na identificação de pragas, tipo de cobertura de solo, reconhecimento

de plantas, inspeção automática de sementes, contagem de frutas, dentre outras [Kamilaris and Prenafeta-Boldú 2018]. As aplicações de AM nesse contexto contribuem diretamente com os objetivos de garantir segurança alimentar em nível global, visto que há perspectiva de aumento na demanda pela produção de alimentos em até 70 % até 2050 em decorrência da rápida urbanização, do aumento populacional, da diminuição do espaço disponível para plantação, dentre outros fatores [Sharma et al. 2021].

No Brasil, o café (do gênero *Coffea*) é uma importante *commodity* agrícola, ocupando o quinto lugar na pauta das exportações. Em 2021, a venda de grãos verdes para o mercado externo movimentou US\$ 5,80 bi, correspondendo a um volume de 38 mi sacas de 60 kg, segundo dados da Associação Brasileira da Indústria de Café (ABIC). A esses números somam-se ainda as variações torrada, moída e solúvel do café [ABIC 2021]. Os climas, relevos, altitudes e latitudes nos diversos estados do país favorecem o cultivo, que totaliza uma área de 2 mi ha em 1.900 municípios, envolvendo cerca de 300 mil produtores. A cafeicultura brasileira é, no mundo, uma das mais atentas às questões sociais e ambientais, características que o tornam o maior produtor e exportador e o segundo maior mercado consumidor da bebida [MAPA 2021].

Para manter um alto grau de qualidade na produção do café, é necessário controlar ou monitorar fatores que a afetam, tais como temperatura, adensamento do solo, regime de chuvas, incidência de ventos, umidade e patologias. Neste último ponto, ressalta-se a importância de um diagnóstico de patologias preciso e precoce, com vistas a auxiliar na tomada de decisão eficaz e eficiente que minimiza os impactos ambientais e econômicos, pois a incidência de fungos, bactérias, nematoides e vírus podem reduzir a produção em até 20 % [de Mesquita et al. 2016].

Visando contribuir para o corpo de soluções inteligentes para a detecção automática de patologias na folha do café para promoção da Agricultura Digital, especialmente considerando o papel desse produto agrícola para o Brasil, este artigo apresenta resultados experimentais do uso de diferentes abordagens baseadas em Redes Neurais Artificiais (RNAs) para esse problema, abordado como uma tarefa de Visão Computacional. A análise dos resultados obtidos mostra-se em consonância com o estado da arte, em que as técnicas de *Deep Learning* sobressaem-se frente à abordagem tradicional de extração de características seguida da classificação com RNAs *Feedforward Multilayer Perceptron* (MLP). Importante ressaltar que tais êxitos foram atingidos a partir de um cenário experimental elaborado com uma base de dados da literatura com cerca de 58 mil exemplos [Jepkoech et al. 2021].

Para apresentar o que se propõe, o presente artigo está organizado como segue. O material e métodos utilizados são apresentados na Seção 3, a qual contempla detalhamentos dos dados experimentais, abordagens, modelos, parametrização e métricas de desempenho. Em seguida, a Seção 4 apresenta os resultados obtidos, uma análise comparativa e relaciona-os com trabalhos existentes na literatura. Por fim, as considerações finais são apresentadas na Seção 5.

## 2. Trabalhos Relacionados

Resultados da aplicação de técnicas de VC para detecção de patologias nas folhas do café já foram reportados na literatura. O trabalho de Dias e Saito [2021], por exemplo, considerou a segmentação das anomalias foliares com o algoritmo JSEG e a sua posterior classificação com RNAs MLP entre exemplos saudáveis e acometidos por duas patologias. Os dados experimentais foram oriundos da base de dados RoCoLe [Parraga-Alava et al. 2019], com 1.560 exemplos, e os resultados alcançados foram fortemente influenciados pelo número e tamanho

dos segmentos derivados.

Redes Neurais Convolucionais (CNNs, do inglês *Convolutional Neural Networks*), principal modelo para classificação de imagens com *Deep Learning*, foram utilizadas no problema de distinção de imagens foliares patológicas acometidas por Ferrugem ou Bicho Mineiro [Işik and Eskicioglu 2022]. Neste trabalho, os autores utilizaram diversas técnicas de pré-processamento de imagens (filtro Gaussiano, equalização do histograma, dentre outras) antes do treinamento de diversas arquiteturas de CNNs. Os resultados obtidos denotaram alta acurácia no problema, o qual foi abordado a partir de uma base de dados com 542 imagens logradas sob condições controladas. Ressalta-se que o uso da solução proposta no referido trabalho demanda uma triagem preliminar entre exemplos saudáveis e doentes.

O trabalho de Aufar *et al.* [2023] fez o uso da mesma base de dados considerada no escopo desta pesquisa. Os autores abordaram o problema como uma tarefa de classificação multiclasse, dividiram a base de dados em 10 partes e efetuaram uma validação cruzada *holdout* em cada uma delas com 80 % dos dados para treinamento, 10 % para validação e 10 % para testes. As arquiteturas de CNNs utilizadas foram ResNet50, InceptionResNetV2, MobileNetV2 e DenseNet169 [Aufar et al. 2023]. Os resultados auferidos evidenciaram uma acurácia experimental de 100 % para as redes InceptionResNetV2 (55,9 mi de parâmetros, 449 camadas) e DenseNet169 (14,3 mi de parâmetros, 338 camadas), mas ressalta-se que os autores não apresentaram medidas de dispersão nas aferições experimentais.

Embora os resultados reportados na literatura já evidenciem bom desempenho das técnicas de *Deep Learning* no problema em questão, observa-se a lacuna de uma análise comparativa entre abordagens clássicas e contemporâneas, a investigação do desempenho de outras arquiteturas de CNNs perante a tarefa em questão e a aferição de como o desempenho das RNAs é influenciado por um menor quantitativo de exemplos de treinamento, o que é um problema prático em diversos contextos em que há dependência de especialistas humanos para elaboração de rótulos. Além de colaborar para mitigar tais lacunas, o presente trabalho também considera uma abordagem experimental com repetições que visam suavizar o viés de flutuação estocástica oriundo da inicialização aleatória dos pesos das RNAs.

### 3. Material e Métodos

O problema de classificação de doenças da folha do café foi abordado no escopo deste trabalho como uma tarefa de classificação multi-classe mediante Aprendizado Supervisionado. A infraestrutura computacional utilizada consistiu em um servidor com Intel(R) Core(TM) i7-8700 CPU @ 3,20 GHz, 32 GB de memória principal, 2,4 TB de memória secundária e 2 GPUs NVIDIA GeForce GTX 1080 Ti com 11 GB de VRAM para aceleração em *hardware* do treinamento. Os dados experimentais, modelos e a avaliação de desempenho da tarefa considerada são descritos detalhadamente nas subseções a seguir.

#### 3.1. Dados Experimentais

Os dados experimentais utilizados no escopo da pesquisa em questão são oriundos das bases de dados JMuBEN e JMuBEN2, as quais são constituídas por 58.550 imagens coloridas rotuladas por especialistas e coletadas no Quênia [Jepkoech et al. 2021]. Além de exemplos saudáveis, contempla quatro patologias foliares do café, a citar: (i) Cercospirose, causada pelo fungo *Cercospora coffeicola*; (ii) Ferrugem, causada pelo fungo *Hemileia vastatrix*; (iii) Bicho Mineiro, causada pelas larvas da mariposa *Leucoptera coffeella*; e (iv) Phoma, causada pelo fungo *Phoma costarricensis*. A Figura 1 ilustra exemplos oriundos dessa base de dados.

É importante ressaltar que os males contemplados nas referidas bases de dados também são incidentes no Brasil [de Mesquita et al. 2016].



Figura 1: Exemplos aleatoriamente selecionados das bases de dados com seus respectivos rótulos. Fonte: [Jepkoech et al. 2021].

Ao observar o quantitativo de exemplos por classe, detalhado no histograma da Figura 2, é importante destacar que a base de dados encontra-se desbalanceada, o que ensejou a adoção de métricas de desempenho compatíveis com esse cenário.

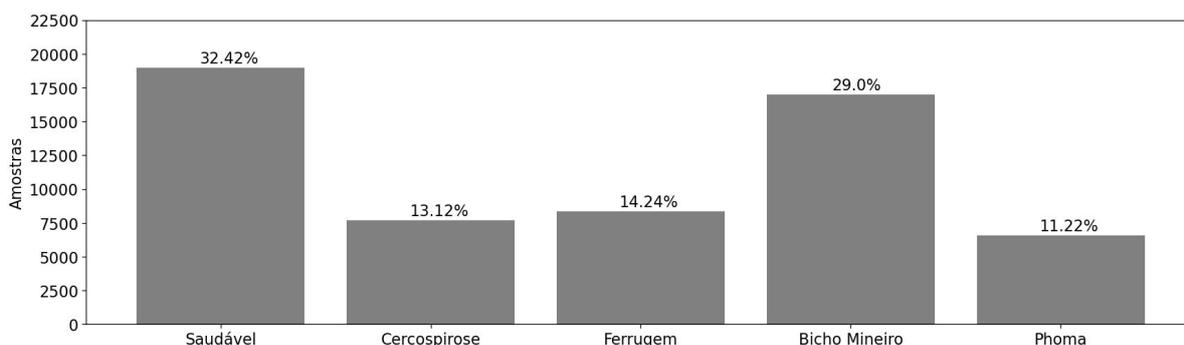


Figura 2: Distribuição de exemplos por classe na base de dados original.

### 3.2. Abordagens, Modelos e Parametrização

Duas abordagens distintas para o problema foram comparadas no escopo deste trabalho, a citar:

1. **Abordagem Tradicional.** Baseou-se no *pipeline* dos métodos de Visão Computacional em que há, primeiramente, a extração de características das imagens e estas são, posteriormente, utilizadas para treinar algoritmos de Aprendizado de Máquina [Prince 2012]. A partir de trabalhos relacionados na literatura no âmbito da Agricultura Digital [Santos et al. 2019], no escopo desta pesquisa foram utilizadas as Características de Haralick [Haralick et al. 1973] por serem capazes de descrever aspectos texturais de imagens calculados no domínio espacial e com natureza estatística; e as RNAs MLP para classificação, pela sua boa capacidade de generalização e desempenho em problemas não-linearmente separáveis de domínios diversos e pela boa tolerância a ruídos nos dados de entrada [Haykin 2008];
2. **Abordagem Contemporânea.** Baseou-se nos progressos recentes de *Deep Learning*, nos quais imagens multidimensionais são fornecidas como entrada para CNNs e estas efetuam o aprendizado automático, massivo e hierárquico dos parâmetros de filtros extratores de características, tornando-se, então, capazes de classificar padrões complexos nos dados de entrada [Goodfellow et al. 2016]. Algumas vantagens dessa

abordagem são a ausência de intervenção humana no processo de extração ou seleção de características e a existência de múltiplas arquiteturas canônicas de CNNs para o domínio de VC [Khan et al. 2018].

A proposição de diferentes arquiteturas de RNAs MLP conforme a Abordagem Tradicional seguiu a Regra da Pirâmide Geométrica [Palit and Popovic 2005], em que:

$$N_h = \alpha \left\lceil \sqrt{N_i N_o} \right\rceil = \alpha \left\lceil \sqrt{13 \cdot 5} \right\rceil = 8\alpha. \quad (1)$$

Como  $0,5 \leq \alpha \leq 2$  e considerando que  $\lceil \cdot \rceil$  denota a função inteiro mais próximo, tem-se:

$$4 \leq N_h \leq 16, \quad (2)$$

em que  $N_i$ ,  $N_o$  e  $N_h$  denotam o número de neurônios nas camadas de entrada, de saída e ocultas, respectivamente. Assim, foram propostas primeiramente 12 RNAs MLP de camada única, contendo de 4 a 16 neurônios ocultos. Para quatro escolhas aleatórias de valores inteiros de  $N_h$  no intervalo especificado, produziu-se todas as arquiteturas derivadas da distribuição da quantidade de neurônios sorteada em duas camadas, resultando em 37 arquiteturas. Todas as 49 RNAs MLP propostas segundo a Abordagem Tradicional utilizaram a função de ativação ReLU (do inglês, *Rectified Linear Unit*) e foram treinadas por 300 épocas com o otimizador Adam.

Para a Abordagem Contemporânea considerou-se o redimensionamento das imagens para  $128 \times 128$  px, a normalização dos valores dos três canais de cores e as seguintes arquiteturas de CNNs:

- 2.1 **MobileNetV2.** É considerada uma CNN leve, tendo sido proposta para utilização em dispositivos móveis e embarcados. Sua arquitetura simplificada utiliza convoluções separáveis em profundidade nas primeiras camadas para diminuir o ônus computacional [Howard et al. 2018]. Há relatos de sua utilização bem sucedida em aplicações de Visão Computacional para Agricultura Digital [Carvalho et al. 2019].
- 2.2 **ShuffleNet.** Também projetada especialmente para dispositivos móveis com poder computacional limitado, utiliza convoluções em grupo, em que cada uma das múltiplas convoluções abrange uma porção dos canais de entrada, e embaralhamento de canais, nos quais aleatoriamente misturam-se os canais de saída das convoluções em grupo, para reduzir significativamente o custo computacional sem causar perda de desempenho [Zhang et al. 2018].
- 2.3 **VGG-16.** Um dos modelos de CNNs mais populares por conta de sua simplicidade e desempenho em tarefas de VC de classificação massiva de objetos. Possui 16 camadas de profundidade, utiliza filtros convolucionais de tamanho  $3 \times 3$  para extração de características, e camadas de *max-pooling* para redução de dimensionalidade, além de camadas finais completamente conectadas para classificação. O uso de filtros menores culmina em um menor número de parâmetros e facilita a paralelização para fins de aceleração em *hardware* do treinamento [Simonyan and Zisserman 2014, Khan et al. 2018].
- 2.4 **InceptionV3.** Tendo o processamento das camadas convolucionais realizado paralelamente, essa arquitetura permite o tratamento das informações ao longo da dimensão de profundidade da entrada. A versão considerada realiza a fatoração de convoluções com o objetivo de reduzir o número de parâmetros sem diminuir a eficiência em problemas de VC [Szegedy et al. 2015, Khan et al. 2018].

**2.5 EfficientNetV2S.** Com quantidade de parâmetros similar à InceptionV3, é uma arquitetura moderna que promove um balanço entre profundidade e quantidade de parâmetros para otimizar conjuntamente a velocidade de treinamento com a eficiência de classificação [Tan and Le 2019]

Para todas as arquiteturas de CNNs selecionadas, os hiperparâmetros foram utilizados conforme os seguintes critérios: (i) os pesos foram inicializados de maneira aleatória, sem transferência de aprendizado ou aproveitamento de pesos de outra tarefa; (ii) o treinamento considerou um número máximo de 300 épocas; (iii) adotou-se a técnica de *Early Stopping* com uma paciência de 30 épocas para evitar *overfitting*, em que foram monitoradas métricas no conjunto de validação; (iv) foi utilizada a técnica de *Model Checkpoint* para monitorar a acurácia no conjunto de validação e persistir em disco o conjunto de pesos que provia melhor generalização; (v) a taxa de aprendizado inicial considerada foi de  $10^{-4}$ ; (vi) foi feito o uso da função de ativação ReLU e (vii) do otimizador Adam; e (viii) a escolha do hiperparâmetro relativo ao tamanho dos *batches* deu-se de forma empírica para cada arquitetura, balanceando a quantidade de parâmetros e a utilização dos recursos computacionais disponíveis, a exemplo da memória principal. As camadas densas e finais de todas as arquiteturas citadas foram redimensionadas para contemplar um número de neurônios compatível com as classes do problema abordado.

### 3.3. Avaliação de Desempenho

Para avaliar os modelos selecionados perante o problema proposto, considerou-se 3 repetições distintas de validações cruzadas do tipo *holdout*, com 60 % dos dados disponíveis para treino, 10 % para validação e 30 % para testes, em que esta última partição foi utilizada para aferir o desempenho. Os valores médios das seguintes métricas de desempenho nas 3 repetições sintetizaram tal avaliação, em que  $C$  denota o conjunto das classes do problema:

$$\text{Acurácia} = \frac{1}{|C|} \sum_{c \in C} \left( \frac{\text{TP}_c + \text{FP}_c}{\text{TP}_c + \text{FP}_c + \text{FN}_c + \text{FP}_c} \right) \quad (3) \quad \text{Precisão} = \frac{1}{|C|} \sum_{c \in C} \left( \frac{\text{TP}_c}{\text{TP}_c + \text{FP}_c} \right) \quad (4)$$

$$\text{Revocação} = \frac{1}{|C|} \sum_{c \in C} \left( \frac{\text{TP}_c}{\text{TP}_c + \text{FN}_c} \right) \quad (5) \quad F_1\text{-Score} = 2 \left( \frac{\text{Precisão} \cdot \text{Revocação}}{\text{Precisão} + \text{Revocação}} \right) \quad (6)$$

Nas Eqs. (3)-(6), as siglas indicam os quatro resultados possíveis de uma tarefa de classificação binária, a citar: TP (do inglês, *True Positive*) demonstra o quantitativo das classificações corretas para a classe positiva; TN (do inglês, *True Negative*), as classificações corretas para a classe negativa; FP (do inglês, *False Positive*), os Erros Tipo I; e FN (do inglês, *False Negative*), os Erros Tipo II.

## 4. Resultados e Discussão

Os experimentos computacionais foram executados respeitando os passos propostos e a síntese dos resultados encontra-se nas Tabelas 1 e 2, as quais denotam, respectivamente, o desempenho das 5 melhores RNAs MLP e das CNNs em termos de média e desvio padrão das 3 repetições efetuadas.

**Tabela 1: Resultados experimentais para a Abordagem Tradicional.**

Arquiteturas	Precisão	Revocação	$F_1$ -Score	Acurácia
(11)	$0.6797 \pm 0.0524$	$0.7227 \pm 0.0070$	$0.6706 \pm 0.0268$	$0.7227 \pm 0.0070$
(14)	$0.6746 \pm 0.0572$	$0.7228 \pm 0.0350$	$0.6757 \pm 0.0566$	$0.7228 \pm 0.0350$
(15)	$0.7036 \pm 0.0900$	$0.7308 \pm 0.0203$	$0.6802 \pm 0.0302$	$0.7308 \pm 0.0203$
(16)	$0.6947 \pm 0.1294$	$0.7304 \pm 0.0280$	$0.6660 \pm 0.0496$	$0.7304 \pm 0.02807$
(8, 7)	$0.6878 \pm 0.0142$	$0.7057 \pm 0.0571$	$0.6661 \pm 0.0492$	$0.7057 \pm 0.0571$

**Tabela 2: Resultados experimentais para a Abordagem Contemporânea.**

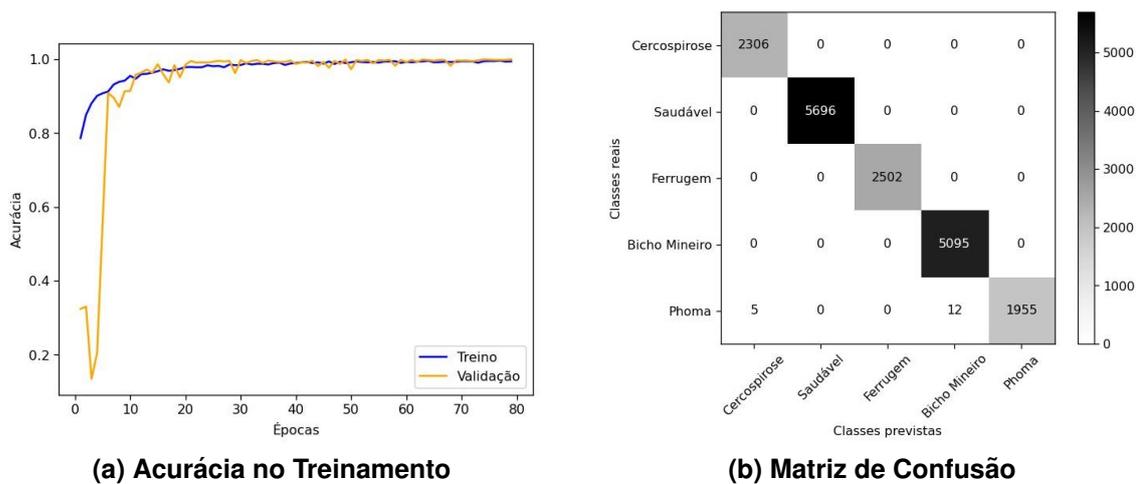
Arquiteturas	Parâmetros	Precisão	Revocação	$F_1$ -Score	Acurácia
<b>MobileNetV2</b>	2,91 mi	$0.0628 \pm 0.0368$	$0.2407 \pm 0.0852$	$0.0987 \pm 0.0547$	$0.2407 \pm 0.0852$
<b>ShuffleNet</b>	1,37 mi	$0.9988 \pm 0.0012$	$0.9988 \pm 0.0012$	$0.9988 \pm 0.0012$	$0.9988 \pm 0.0012$
<b>InceptionV3</b>	22,85 mi	$0.9990 \pm 0.0001$	$0.9990 \pm 0.0002$	$0.9990 \pm 0.0002$	$0.9990 \pm 0.0002$
<b>VGG-16</b>	18,91 mi	$0.9861 \pm 0.0099$	$0.9852 \pm 0.0109$	$0.9847 \pm 0.0115$	$0.9852 \pm 0.0109$
<b>EfficientNetV2S</b>	22,85 mi	$0.9986 \pm 0.0004$	$0.9986 \pm 0.0004$	$0.9986 \pm 0.0004$	$0.9986 \pm 0.0004$

Ao elencar o  $F_1$ -Score como métrica de referência, é notável que a Abordagem Tradicional fica aquém da Abordagem Contemporânea. Isso é particularmente interessante do ponto de vista prático, pois a primeira é fortemente dependente da intervenção e *expertise* humanas para extração de características e proposição de arquiteturas.

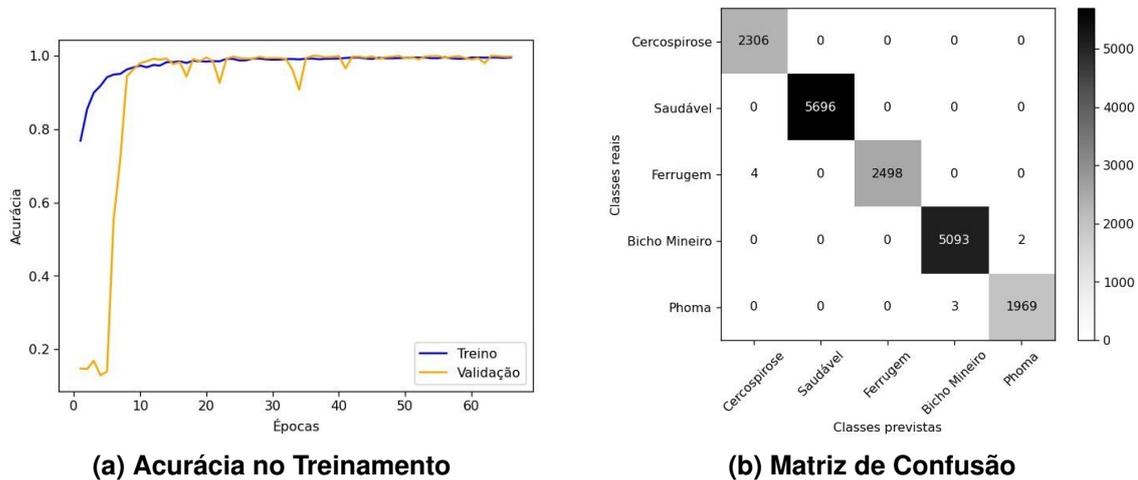
Ao examinar os resultados obtidos com a Abordagem Contemporânea, primeiramente é notável destacar a degradação do desempenho da MobileNetV2 quando comparada aos resultados reportados no trabalho de Aufar *et al.* [2023], em que se pôde verificar que o desempenho deste modelo é fortemente dependente da alta disponibilidade de dados de treinamento. Essa é uma consideração relevante na ocasião da preparação de tal arquitetura para outros problemas da Agricultura Digital.

As demais arquiteturas da Abordagem Contemporânea obtiveram  $F_1$ -Score médio acima de 98 %, dentre as quais destacaram-se a InceptionV3 (23,9 mi de parâmetros, 189 camadas) e a ShuffleNet (1,37 mi de parâmetros, 50 camadas), vide Figuras 3 e 4, respectivamente. Em comparação aos resultados obtidos por Aufar *et al.* [2023], tem-se um desempenho equivalente, mas com arquiteturas menores e treinadas com significativamente menos dados. A InceptionV3 e a ShuffleNet possuem, respectivamente, 57,24 % e 97,54 % menos parâmetros que a InceptionResNetV2. Embora a InceptionV3 possua mais parâmetros que a DenseNet169, possui menor profundidade, o que pode impactar no tempo de treinamento. A ShuffleNet é menor que a DenseNet169 em ambas as dimensões.

Considerando o desempenho muito similar das CNNs InceptionV3 e ShuffleNet nos experimentos realizados, foi elaborado o teste estatístico não-paramétrico de Wilcoxon com nível de confiança de 95 % para investigar a hipótese nula de que o desempenho de ambas as redes é similar perante o problema. Como resultado, obteve-se um  $p$ -valor igual a 1, que é maior que  $\alpha = 0.05$ , indicando que não é possível rejeitar a hipótese nula. Nesses termos, elenca-se então a ShuffleNet como solução de referência neste trabalho, por ser consideravelmente pequena em termos de parâmetros e camadas, o que implica em menor ônus computacional para treinamento e inferência, além de favorecer a sua utilização em dispositivos embarcados, tais como em Veículos Aéreos Não Tripulados (VANTs), o que pode colaborar para o monitoramento remoto de plantações de café no tocante às patologias consideradas.



**Figura 3: Artefatos visuais coletados de uma das repetições experimentais da InceptionV3.**



**Figura 4: Artefatos visuais coletados de uma das repetições experimentais da ShuffleNet.**

## 5. Considerações Finais

Este trabalho teve por objetivo comparar o desempenho de duas abordagens de utilização de RNAs perante o problema de VC de classificação multi-classe de patologias foliares do café. Para tanto, considerou uma base de dados realística e um cenário experimental com validação cruzada e repetições. Os resultados obtidos evidenciaram que as CNNs mostram-se mais adequadas para essa tarefa, com métricas comparáveis ao estado da arte, mas obtidas com um número significativamente menor de dados de treinamento e de parâmetros com a arquitetura ShuffleNet. Tais resultados colaboram para a adoção da solução proposta em contextos aplicáveis da Agricultura Digital.

Em trabalhos futuros, almeja-se expandir os experimentos para englobar outras bases de dados, especialmente se houver exemplos oriundos do Brasil, bem como expandir os experimentos incluindo outras arquiteturas leves de CNNs.

## Agradecimentos

As autoras agradecem o apoio financeiro do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e da Fundação de Amparo à Pesquisa do Estado do Amazonas (FA-

PEAM) fornecidos, respectivamente, por meio dos programas PAIC 2021/2022 e 2022/2023. Agradecemos também o apoio material do Laboratório de Sistemas Inteligentes (LSI) da Universidade do Estado do Amazonas (UEA).

## Referências

- ABIC (2021). Associação Brasileira da Indústria de Café, estatísticas da exportação brasileira de café. Disponível em <https://estatisticas.abic.com.br>. Acesso em 25 de maio de 2023.
- Aufar, Y., Abdillah, M. H., and Romadoni, J. (2023). Web-based CNN application for Arabica Coffee leaf disease prediction in smart agriculture. *J. RESTI (Rekayasa Sist. Dan Teknol. Inf.)*, 7(1):71–79.
- Carvalho, V., Guedes, E., and Salame, M. (2019). Classificação de ervas daninhas em culturas agrícolas com comitês de redes neurais convolucionais. *Encontro Nacional de Inteligência Artificial e Computacional (ENIAC)*, pages 60–71. Disponível em: <https://doi.org/10.5753/eniac.2019.9272>.
- de Mesquita, C. M., de Rezende, J. E., Carvalho, J. S., Júnior, M. A. F., Moraes, N. C., Dias, P. T., de Carvalho, R. M., and de Araújo, W. G. (2016). *MANUAL DO CAFÉ – DISTÚRBIOS FISIOLÓGICOS, PRAGAS E DOENÇAS DO CAFEIEIRO*. EMATER, Belo Horizonte, 1 edition.
- Dias, J. and Saito, J. (2021). Coffee plant image segmentation and disease detection using jseg algorithm. In *Anais do XVII Workshop de Visão Computacional*, pages 42–47, Porto Alegre, RS, Brasil. SBC.
- Embrapa (2014). *Visão 2014–2034 – O Futuro do Desenvolvimento Tecnológico da Agricultura Brasileira (Síntese)*. Embrapa, Distrito Federal, Brasil.
- Faceli, K., Lorena, A. C., Gama, J., and de Carvalho, A. C. P. L. F. (2021). *Inteligência Artificial – Uma abordagem de aprendizado de máquina*. Editora LTC, Rio de Janeiro, 2 edition.
- Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep Learning*. The MIT Press, Cambridge.
- Haralick, R. M., Shanmugam, K., and Dinstein, I. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-3(6):610–621.
- Haykin, S. (2008). *Neural Networks and Learning Machines*. Pearson Prentice-Hall, Estados Unidos, 3 edition.
- Howard, A., Sandler, M., Zhu, M., Zhmoginov, A., and Chen, L.-C. (2018). Mobilenetv2: Inverted Residuals and Linear Bottlenecks. *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 4510–4520. Disponível em: <https://arxiv.org/abs/1801.04381>.
- Işik, A. H. and Eskicioglu, Ö. C. (2022). Classification of coffee leaf diseases through image processing techniques. In *Artificial Intelligence and Smart Agriculture Applications*, pages 233–252. Auerbach Publications, Estados Unidos.
- Jepkoech, J., Mugo, D. M., Kenduiywo, B. K., and Too, E. C. (2021). Arabica coffee leaf images dataset for coffee leaf disease detection and classification. *Data in Brief*, 36:107–142.

- Kamilaris, A. and Prenafeta-Boldú, F. X. (2018). Deep Learning in Agriculture: A Survey. *Computers and Electronics in Agriculture*, 147:70–90.
- Khan, S., Rahmani, H., Shah, S. A. A., and Bennamoun, M. (2018). *A Guide to Convolutional Neural Networks for Computer Vision*. Synthesis Lectures on Computer Vision. Morgan & Claypool, San Rafael, California, USA, 1a edition.
- MAPA (2019). Ministério da Agricultura, Pecuária e Abastecimento, Panorama do Agonegócio Brasileiro. Disponível em <http://www.agricultura.gov.br>. Acesso em 25 de maio de 2023.
- MAPA (2021). Ministério da Agricultura, Pecuária e Abastecimento, Panorama do Agonegócio Brasileiro, café no Brasil e Ementário do Café. Disponível em <https://www.gov.br/agricultura/pt-br/assuntos/politica-agricola/cafe/cafeicultura-brasileira>. Acesso em 25 de maio de 2023.
- Palit, A. K. and Popovic, D. (2005). *Computational Intelligence in Time Series Forecasting*. Springer-Verlag, Londres.
- Parraga-Alava, J., Cusme, K., Loor, A., and Santander, E. (2019). RoCoLe: A robusta coffee leaf images dataset for evaluation of machine learning based methods in plant diseases recognition. *Data in Brief*, 25(104414).
- Prince, S. (2012). *Computer Vision: Models, Learning, and Inference*. Cambridge University Press, Cambridge.
- Santos, F., Canuto, A., Bedregal, B., Palmeira, E., and Silva, I. (2019). Supervised methods applied to the construction of a vision system for the classification of cocoa beans in the cut-test. In *Anais do XVI Encontro Nacional de Inteligência Artificial e Computacional*, pages 72–83, Porto Alegre, RS, Brasil. SBC. Disponível em <http://dx.doi.org/10.5753/eniac.2019.9273>. Acesso em 25 de maio de 2023.
- Sharma, A., Jain, A., Gupta, P., and Chowdary, V. (2021). Machine learning applications for precision agriculture: A comprehensive review. *IEEE Access*, 9:4843–4873.
- Simonyan, K. and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. Disponível em <https://arxiv.org/abs/1409.1556>. Acesso em 25 de maio de 2023.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, volume 1, pages 1–9, Massachusetts, Estados Unidos. IEEE.
- Tan, M. and Le, Q. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. In *Proceedings of the 36th International Conference on Machine Learning*, volume 97, pages 6105–6114.
- Tang, S., Zhu, Q., Zhou, X., Liu, S., and Wu, M. (2002). A Conception of Digital Agriculture. In *IEEE International Geoscience and Remote Sensing Symposium*, pages 3026–3028, Canada. IEEE.
- Zhang, X., Zhou, X., Lin, M., and Sun, J. (2018). Shufflenet: An extremely efficient convolutional neural network for mobile devices. In *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pages 6848–6856, Estados Unidos. IEEE.