

# Detecção de Patologias em Folhas de Tomateiros Utilizando Dois Classificadores

Leonardo Marçal da Silva, Luana Rodrigues Barros, Maísa Lauriane F. dos Santos e Carlos Danilo Miranda Regis

**Resumo**—A detecção precoce de patologias em plantações utilizando algoritmos de aprendizado de máquina pode minimizar drasticamente o uso de agrotóxicos, reduzindo perdas e melhorando a qualidade dos alimentos. Nesse cenário, este trabalho propõe uma abordagem baseada na utilização de duas redes neurais convolucionais (RNCs) atuando paralelamente para discriminar folhas saudáveis de folhas afetadas por patologias. Quando comparada com a classificação realizada por uma única RNC, a abordagem se mostrou eficiente para arquiteturas mais simples, tendo o potencial de melhorar a classificação dos dados.

**Palavras-Chave**—Redes neurais convolucionais, folhas, classificação, patologias, plantas.

**Abstract**—Early detection of pathologies in plantations using machine learning algorithms can drastically minimize the use of pesticides, reducing losses and improving food quality. In this scenario, this work proposes an approach based on the use of two convolutional neural networks (CNNs) acting in parallel to discriminate healthy leaves from leaves affected by pathologies. When compared to the classification performed by a single CNN, the approach proved to be efficient for small architectures, having the potential to improve data classification.

**Palavras-chave**—Convolutional neural networks, leaves, classification, pathologies, plants.

## I. INTRODUÇÃO

As novas tecnologias possibilitaram a expansão da capacidade de produção de alimentos para atender à demanda mundial. As doenças das plantas não são apenas uma ameaça à segurança alimentar em escala global, mas também podem ter consequências desastrosas para os pequenos agricultores cujo sustento depende de safras saudáveis e isto ocorre devido a ameaça de diversos fatores tais como: mudanças climáticas, doenças de plantas, o declínio dos polinizadores, pestes e outros [1].

O tomate é uma das culturas mais produzidas em todo o mundo. Entretanto, esta produção é afetada por uma variedade de pragas e doenças do tomateiro que comprometem seriamente a produção do tomate, tais como: mancha bacteriana, mancha precoce, mancha tardia, mosaico vírus e folhas amarelas e curvadas [2]. Para prevenir essas doenças e pragas, métodos caros e vários pesticidas são usados na agricultura. O uso generalizado desses métodos químicos prejudicam a saúde das plantas e a saúde humana, além de afetar negativamente o meio ambiente. Para controlar com eficácia as pragas e doenças, é importante identificá-las precisamente [3].

Leonardo Marçal da Silva, Luana Rodrigues Barros, Maísa Lauriane F. dos Santos e Carlos Danilo Miranda Regis Academic Unit 3, Federal Institute of Paraíba (IFPB), João Pessoa-PB, Brazil, E-mails: marcal.leonardo@academico.ifpb.edu.br, luana.barros@academico.ifpb.edu.br, maisa.lauriane@academico.ifpb.edu.br e danilo.regis@ifpb.edu.br.

O diagnóstico de doenças de plantas, tradicionalmente, é realizado por meio de observação visual por especialistas. No entanto, existe o risco de erro devido à percepção subjetiva dos inúmeros problemas fitopatológicos existentes, além do grande número de plantas que normalmente são cultivadas. Mesmo agrônomos e fitopatologistas experientes muitas vezes não conseguem diagnosticar doenças específicas e, consequentemente, são levados a conclusões e tratamentos equivocados [4]. Neste contexto, diversas técnicas espectroscópicas e de imagem têm sido estudadas para a detecção de doenças em plantas. No entanto, elas requerem instrumentos precisos e sensores volumosos, o que leva a um alto custo e baixa eficiência [5] [6].

Nos últimos anos, com a popularização de câmeras digitais e outros dispositivos eletrônicos, o diagnóstico automático de doenças de plantas via aprendizado de máquina tem sido amplamente aplicado como alternativa viável. Nesse cenário, Tm et al. [7] utilizou em seu trabalho aprendizagem profunda, AlexNet e VGG16 net para detecção de doenças em folhas de tomate. A precisão da classificação usando 13.262 imagens foram 97,29% para a rede VGG16 e 97,49% para a AlexNet. Durmuş et al. [3] em seu trabalho realizou a detecção de diversas patologias em plantações de tomate, utilizando redes neurais profundas AlexNet e SqueezeNet, embarcadas em um robô que pode vagar pela plantação de forma manual ou autônoma. A acurácia no teste para AlexNet foi de 95,65%, já para SqueezeNet foi 94,3%. Kurmi et al. [8] discriminou em seu trabalho os diferentes tipos de patologias de três conjuntos de dados da base PlantVillage, usando como classificadores uma MLP (*Multi Layer Perceptron*) e uma SVM (*Support Vector Machine*) após um pré-processamento e extração de características para as folhas de tomates obteve uma acurácia de 89,2% com a MLP e 91,8% com a SVM.

Aplicações baseadas em processamento de imagens e aprendizado de máquina podem representar facilidade de uso, acessibilidade, baixo custo e uma boa acurácia. Além disso, no caso de cultivos em grande escala, o sistema poderia ser combinado com veículos autônomos, para localizar problemas fitopatológicos de forma precisa e oportuna em todo o campo de cultivo, usando a captura contínua de imagens [4].

Neste trabalho, foi proposta uma abordagem baseada na utilização de redes neurais convolucionais (RNCs) para discriminar folhas saudáveis de folhas afetadas por patologias. Mais precisamente, duas RNCs foram utilizadas simultaneamente para a classificação das amostras. Com o auxílio de técnicas de pré-processamento e segmentação, uma das redes considerou apenas o formato das folhas enquanto a outra considerou, sobretudo, o aspecto e textura da superfície. Para que uma

amostra fosse considerada saudável, ambos os classificadores a consideraram saudável. Os classificadores foram treinados e testados com imagens de folhas de tomate do conjunto de dados Plantvillage. Para fins de comparação, um experimento também foi feito utilizando uma única RNC para classificar os dados. Além disso, o experimento foi executado de duas maneiras: 1) utilizando RNCs cuja arquitetura foi proposta pelos autores, e 2) utilizando a Teachable Machine, uma ferramenta online para criação de modelos otimizados de aprendizado de máquina. Por fim, uma discussão detalhada foi feita acerca da abordagem desenvolvida, levando em consideração as duas arquiteturas utilizadas.

## II. BASE DE DADOS

O banco de dados utilizado neste trabalho foi o *PlantVillage* [9], amplamente utilizado na identificação e classificação de doenças que acometem diversos tipos de plantas. O conteúdo deste banco de dados é especificamente de folhas saudáveis e de folhas com diversas patologias. Para o trabalho de classificação, foram selecionadas apenas as imagens do conjunto de folhas de tomateiros (18.163 imagens). Este segmento foi escolhido devido a larga quantidade de imagens e variedade de patologias disponíveis. Na Tabela I podem ser visualizados os números para cada patologia e para as folhas saudáveis.

TABELA I  
BASE DE DADOS.

Classe	Número de imagens
<b>Saudáveis</b>	1591
Mancha bacteriana	2127
Peste precoce	1000
Peste tardia	1909
Mofo	952
<b>Patologias</b>	
Mancha na folha	1771
Ácaros de aranhas	1676
Mancha-alvo na folha	1404
Folhas amareladas e curvas	5257
Vírus do mosaico	373

## III. METODOLOGIA

### A. Limpeza da Base

O processo de limpeza de dados é necessário para remover as amostras que se mostrem imprecisas ou inconsistentes em relação ao restante das amostras do banco de dados. Em treinamentos de algoritmos de aprendizagem de máquina, como é o caso das RNCs, dados inconsistentes podem aumentar a taxa de erros, fazendo com que a generalização obtida não acompanhe a variação intraclasses dos dados. Portanto, garantir uma boa qualidade dos dados aumenta a probabilidade de alcançar um modelo que produza bons resultados.

Uma limpeza foi feita na base de dados escolhida. Foram removidas amostras cujo conteúdo apresentasse objetos de não interesse (como frutos, raízes e galhos) e excesso de sombras. Além disso, foram removidas imagens que já se encontravam segmentadas. Também foram retiradas da base as imagens que não apresentavam a folha completa, já que a abordagem proposta neste estudo leva em consideração o formato da folha.

Na Figura 1 são apresentados alguns exemplos de imagens removidas do banco de dados.



Fig. 1. Exemplos de imagens removidas da base de dados

### B. Pré-processamento

No pré-processamento das imagens foi utilizada uma correção *gamma*  $g(u) = u^\gamma$ , na qual  $\gamma = 0.75$ , com o intuito de aumentar a luminosidade da imagem. Essa técnica possibilitou uma melhor distinção entre o fundo da imagem e a folha. Posteriormente foi aplicado um filtro de média com *kernel*  $5 \times 5$ .

### C. Segmentação

Após o pré-processamento, foi aplicado um algoritmo de segmentação das folhas nas imagens. A identificação do fundo da imagem foi feita com base na análise de cores. Mais especificamente, as imagens foram convertidas para o espaço de cores HSV, de forma que um limiar pôde ser mais facilmente traçado entre as cores do fundo e as da folha. Na Tabela II, podem ser observados os limiares inferiores e superiores que permitiram a identificação do fundo da imagem.

TABELA II  
LIMIARES PARA IDENTIFICAÇÃO DO FUNDO DA IMAGEM.

Limiar	H (matiz)	S (saturação)	V (valor)
Inferior	19	26	11
Superior	92	255	255

Após encontrar o limiar inferior e superior do espaço de cores HSV que caracterizam o fundo da imagem, foi possível obter uma máscara. A fim de remover ruídos, foram aplicadas algumas operações morfológicas na máscara obtida, sendo: erosão com *kernel*  $3 \times 3$ , dilatação com *kernel*  $5 \times 5$  e erosão com *kernel*  $3 \times 3$ . Todas com elemento estruturante quadrado.

Por fim, a máscara obtida aplicada na imagem original, removendo o fundo da imagem, de forma que apenas a área que contém a folha é destacada. Na Figura 2 são apresentadas as etapas utilizadas na obtenção da máscara e da imagem após a aplicação da máscara.

### D. Classificadores

Nos últimos anos, as redes neurais convolucionais têm se consolidado como ferramentas de extrema eficácia em problemas de classificação de imagens. Resumidamente, as camadas convolucionais são as mais importantes deste tipo de rede e consistem na aplicação de filtros com tamanho de *kernel* fixo. As camadas de *pooling* são utilizadas para

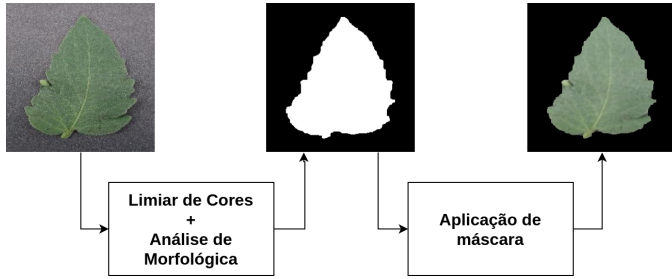


Fig. 2. Segmentação por meio da aplicação de máscara.

reduzir o tamanho da imagem de entrada, reduzindo também o custo computacional, o uso de memória e a quantidade de parâmetros. A camada *flatten* tem a finalidade de converter os dados matriciais em formato de vetores unidimensionais para que esses dados possam ser usados como entradas nas camadas totalmente conectadas do classificador [3].

Para este estudo, foram elaborados dois classificadores baseados em redes neurais convolucionais. A mesma arquitetura foi utilizada para gerar o modelo de ambos. O primeiro classificador levou em consideração todas as patologias que causam alteração no aspecto e textura da superfície e o segundo classificador levou em consideração as patologias que causam danos ao formato da folha. A distribuição dessas patologias é apresentada na Figura 3. Observa-se que, para algumas patologias, ambas as características podem ocorrer, dessa forma, essas patologias compõem as duas redes.

Nesse cenário, chama-se de "classificador 01" o que leva em consideração textura e aspecto da superfície e "classificador 02" o que leva em consideração o formato das folhas. No classificador 01, antes do treinamento, as imagens tiveram seu fundo removido pelo algoritmo de segmentação desenvolvido. Para o classificador 02, as imagens de entrada consistiram nas máscaras geradas na etapa de segmentação, contendo apenas a silhueta da folha. Estas etapas também podem ser observadas no diagrama da Figura 3.

1) *RNC dos autores*: Na Figura 4 é apresentado um resumo da arquitetura de RNC desenvolvida para o problema. Consistiu, basicamente, em três camadas convolucionais, compostas por 32 filtros de tamanho  $3 \times 3$ , seguida de uma camada convolucional com 64 filtros de tamanho  $3 \times 3$ , mais uma camada convolucional composta por 32 filtros de tamanho  $3 \times 3$ . Cada camada convolucional foi seguida de operadores do tipo *max pool*. A saída dos últimos operadores segue, por fim, para uma camada *flatten* e duas camadas totalmente conectadas. Como entrada, a rede do classificador 01 recebe imagens coloridas, de dimensões  $256 \times 256 \times 3$ . Já o classificador 02 recebe imagens binárias com dimensões  $256 \times 256 \times 1$ . A função de ativação ReLU foi aplicada nas camadas convolucionais em ambos os classificadores, com o objetivo principal de evitar o problema fuga do gradiente, que pode ser contido devido ao valor atribuído ao gradiente ser sempre constante. As camadas de *pooling* tiveram o processo de discretização baseado no valor máximo do campo receptivo. Essa operação também é conhecida como *pooling* máximo, que foi aplicada com um núcleo  $2 \times 2$  e um passo de 2. Por fim, a camada *flatten* foi utilizada para converter o último mapa de características em

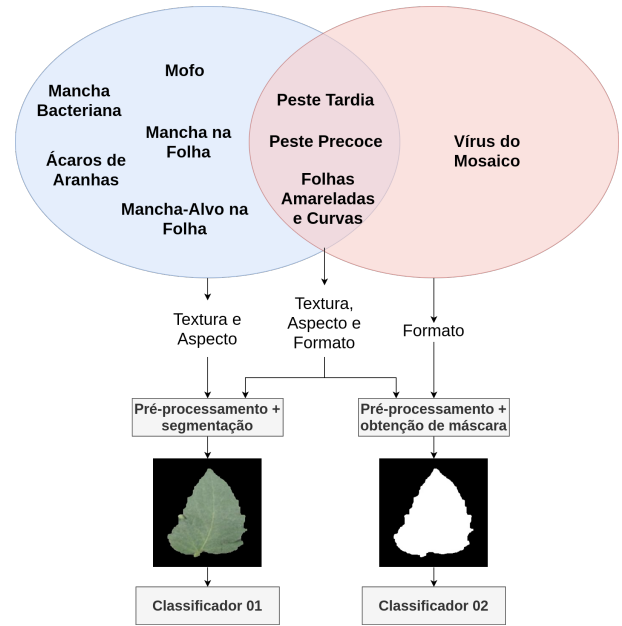


Fig. 3. Separação de patologias que causam danos à superfície ou danos ao formato da folha.

um vetor unidimensional, que por sua vez, foi utilizado como entrada da primeira camada totalmente conectada. Na última camada da rede, foi utilizada a função de ativação sigmoide, dado a natureza binária da classificação.

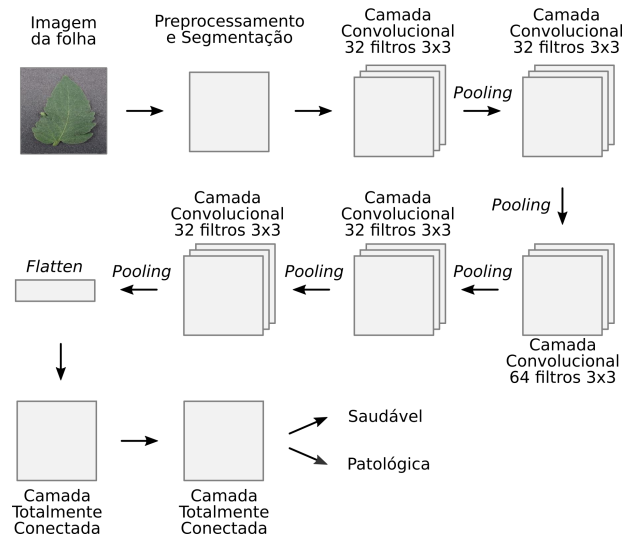


Fig. 4. Arquitetura da RNC desenvolvida

2) *Teachable Machine*: A Teachable Machine é uma ferramenta desenvolvida pelo Google, baseada em uma técnica popular de aprendizado profundo chamada transferência de aprendizado. Nesse tipo de abordagem, a maior parte da arquitetura da rede neural de um modelo totalmente treinado é mantida, enquanto substitui uma pequena parte dela com base nos dados. Após o treinamento da rede, ainda é possível fazer o download do modelo. Sendo assim, na etapa de classificação, foi possível aplicar a mesma metodologia tanto para o modelo obtido por meio da RNC desenvolvida quanto para o modelo obtido com a Teachable Machine.

3) *Treinamento*: Devido ao pequeno número de amostras saudáveis quando somada todas as amostras patológicas, o conjunto de patologias foi subamostrado. Sendo assim, para o classificador 01 foram selecionadas 200 imagens de cada doença para compor o conjunto patológico, enquanto que para o classificador 02 foram selecionadas 300 imagens de cada patologia. Cada classificador levou em conta apenas as patologias associadas no diagrama da Figura 3. Todas as imagens saudáveis foram utilizadas em ambos os classificadores. Cada classificador teve 75% do seu conjunto reservado para treinamento e 25% para teste. As mesmas amostras foram reservadas no conjunto de treinamento e de teste quando as patologias afetam a textura e o formato da folha simultaneamente. Portanto, é importante evidenciar que no conjunto de teste do classificador 01 não possui imagens contidas no conjunto de treino do classificador 02, assim como a recíproca também é verdadeira. Isso permite que os conjuntos de testes possam ser utilizados em conjunto para a discriminação das imagens aplicando os dois classificadores simultaneamente.

Para os classificadores obtidos por meio da arquitetura elaborada neste estudo, foram utilizados um algoritmo de retropropagação para estimar os parâmetros da rede, que consiste em um método de otimização da função custo baseado no vetor gradiente descendente. Mais especificamente, o algoritmo otimizador Adam foi usado, com uma taxa de aprendizagem  $\eta = 10^{-4}$ ,  $\beta_1 = 0.9$ ,  $\beta_2 = 0.999$  e  $\epsilon = 10^{-7}$ .

4) *Classificação*: Ao conjunto de testes do classificador 01 foram adicionadas as patologias complementares contidas no conjunto de testes do classificador 02. Este novo conjunto de testes foi utilizado para testar a eficiência dos dois classificadores aplicados em conjunto. Como decisão final, o sistema com os dois classificadores considera que a amostra é saudável apenas se ambos a classificarem como saudável. Caso contrário, a amostra é considerada patológica.

#### IV. RESULTADOS

A avaliação de desempenho de uma rede neural consiste em verificar se a classe prevista corresponde, de fato, à classe da amostra de entrada. Pode-se considerar que uma amostra patológica corresponde a uma classe positiva, enquanto uma amostra saudável corresponde a uma classe negativa. Diante disso, quatro desfechos podem ser considerados: verdadeiros positivos (TP), falsos positivos (FP), verdadeiros negativos (TN) e falsos negativos (FN). Algumas medidas, como acurácia, sensibilidade e especificidade, podem ser obtidas a partir dos parâmetros TP, FP, TN e FN, contribuindo para a avaliação do desempenho da rede.

- **Acurácia** – Indica a capacidade da rede de classificar as amostras corretamente. É matematicamente expresso pela Equação 1.

$$\text{Acurácia} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (1)$$

- **Sensibilidade** – Mede a capacidade da rede de identificar corretamente as amostras patológicas. É matematicamente expresso pela Equação 2.

$$\text{Sensibilidade} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (2)$$

- **Especificidade** – Mede a capacidade da rede de determinar corretamente amostras saudáveis. É matematicamente expresso pela Equação 3.

$$\text{Especificidade} = \frac{\text{TN}}{\text{TN} + \text{FP}} \quad (3)$$

Neste estudo, foi elaborada uma arquitetura de RNC, que foi utilizada em dois treinamentos para a geração de dois modelos. Os respectivos modelos foram, por sua vez, utilizados de forma conjunta na classificação do conjunto de testes. Além da classificação baseada na utilização dos dois classificadores obtidos por meio da arquitetura elaborada, outra classificação baseada em dois classificadores foi feita utilizando a ferramenta Teachable Machine [10]. Com ela, outros dois modelos foram gerados e utilizados na classificação do conjunto de testes.

Para fins de comparação, a mesma arquitetura foi utilizada para treinamento com a base, porém, sem distinção das patologias que afetam a textura e das que afetam o formato. A mesma coisa foi feita utilizando a ferramenta Teachable Machine [10]. A base foi composta de todas as amostras saudáveis e de 200 amostras de cada patologia. Destas, 75% foram reservadas para treinamento e 25% para teste. Foi aplicada a remoção de fundo em todas as imagens da base. Desse modo, considera-se que:

- M1**: Método baseado na utilização de dois classificadores
- M2**: Método baseado na utilização de apenas um classificador

Na Tabela III é apresentada uma análise comparativa entre a abordagem proposta, baseada na utilização de dois classificadores, e em uma abordagem baseada na utilização de apenas um classificador.

TABELA III  
CLASSIFICAÇÃO DO CONJUNTO DE TESTES.

Métricas	RNC Desenvolvida		Teachable Machine	
	M1	M2	M1	M2
Acurácia (%)	91,63	90,63	95,69	<b>97,43</b>
Sensibilidade (%)	94,00	87,67	95,29	<b>98,21</b>
Especificidade (%)	87,92	96,20	<b>96,39</b>	96,25

Observa-se que a melhor acurácia foi obtida pela classificação com uma única rede utilizando a arquitetura proposta pela ferramenta Teachable Machine. Como mostra a coluna M2 desta abordagem, a rede se manteve consistente tanto para a classificação de amostras patológicas quanto para a classificação de amostras saudáveis. Contudo, a abordagem que obteve o melhor desempenho na classificação de amostras saudáveis foi a que utilizou dois classificadores treinados com a ferramenta Teachable Machine, como indica a especificidade.

Entre os métodos M1 e M2 elaborados com a arquitetura de RNC desenvolvida, foi possível perceber que a abordagem que utilizou dois classificadores obteve melhor acurácia. O método M1 também apresentou uma tendência de melhorar

discriminação imagens patológicas, enquanto que piorou a determinação das amostras saudáveis.

Em relação às arquiteturas, observa-se que a abordagem baseada na utilização de dois classificadores simultâneos obteve um melhor desempenho, considerando a acurácia e a sensibilidade, com a estrutura de RNC desenvolvida, mais simples do que a proposta pela Teachable Machine. A abordagem dos dois classificadores se mostrou menos eficiente em determinar corretamente amostras saudáveis.

## V. CONCLUSÕES

Este estudo propôs a utilização de dois classificadores baseados em RNCs para discriminação entre amostras saudáveis e patológicas de tomateiros. Para corroborar com a análise dos resultados, duas arquiteturas foram utilizadas para a averiguação do método. Além disso, foram executadas classificações baseadas em um único classificador. A comparação entre estes métodos mostrou que o impacto de dois classificadores foi mais evidente em uma arquitetura de RNC menos complexa, como a proposta neste trabalho. Apesar de uma melhora na classificação de imagens patológicas, aumentou o erro na determinação de imagens saudáveis.

Com a arquitetura de rede proposta pela ferramenta Teachable Machine, a utilização de dois classificadores diminuiu ou manteve similar os valores para todas as métricas calculadas quando comparada a classificação feita por uma única rede. Apesar de um leve aprimoramento na classificação de imagens saudáveis, a utilização de duas redes pode ser dispensada, reduzindo custo computacional.

Percebe-se então que, para arquiteturas mais simples, a utilização de dois classificadores tem o potencial de melhorar a classificação dos dados. Para redes de arquitetura mais robustas, como a apresentada pela ferramenta Teachable Machine, essa abordagem torna-se dispensável.

Ademais, a utilização de duas redes pode ser melhor aproveitada para outras bases de dados que possuam variação de formato entre as classes mais definidas, bem como variação de aspecto da superfície.

Destaca-se também que, por meio da metodologia aplicada neste trabalho, foi possível encontrar um dos melhores resultados de acurácia quando comparado ao estado da arte. Quando aplicado o modelo obtido com a Teachable Machine com a utilização de apenas um classificador, a acurácia obtida atingiu 97,43%, enquanto que a sensibilidade chegou à 98,21%. É provável que as etapas de limpeza da base e pré-processamento tenham colaborado de forma bastante positiva na obtenção de tais resultados.

As contribuições deste trabalho são inéditas, dado que nenhum estudo encontrado no estado da arte utilizou mais de um classificador para este propósito. Além disso, é importante evidenciar o esforço empregado na limpeza da base de dados, removendo amostras que influenciariam de maneira negativa na eficácia do modelo obtido. Não foram encontrados trabalhos que empregassem essa abordagem até o momento em que esta pesquisa foi desenvolvida.

Em trabalhos futuros, pretende-se expandir esta pesquisa, realizando a classificação multiclasse das amostras da base.

Além disso, outras bases de dados, correspondentes às folhas de outras espécies de plantas frutíferas, podem ser utilizadas para reavaliar a eficiência dos dois classificadores.

## VI. AGRADECIMENTOS

Agradecemos à Pró-Reitoria de Pesquisa, Inovação e Pós-Graduação do IFPB pelo incentivo a este trabalho.

## REFERÊNCIAS

- [1] S. Mohanty, D. Hughes, and M. Salathe, “Using deep learning for image-based plant disease detection,” *Frontiers in Plant Science*, vol. 7, 04 2016.
- [2] J. Shijie, J. Peiyi, H. Siping, and s. Haibo, “Automatic detection of tomato diseases and pests based on leaf images,” in *2017 Chinese Automation Congress (CAC)*, 2017, pp. 2537–2510.
- [3] H. Durmuş, E. O. Güneş, and M. Kırıcı, “Disease detection on the leaves of the tomato plants by using deep learning,” in *2017 6th International Conference on Agro-Geoinformatics*, 2017, pp. 1–5.
- [4] K. Ferentinos, “Deep learning models for plant disease detection and diagnosis,” *Computers and Electronics in Agriculture*, vol. 145, pp. 311–318, 02 2018.
- [5] P. Jiang, Y. Chen, B. Liu, D. He, and C. Liang, “Real-time detection of apple leaf diseases using deep learning approach based on improved convolutional neural networks,” *IEEE Access*, vol. 7, pp. 59 069–59 080, 2019.
- [6] L. Yuan, Y. Huang, R. W. Loraamm, C. Nie, J. Wang, and J. Zhang, “Spectral analysis of winter wheat leaves for detection and differentiation of diseases and insects,” *Field Crops Research*, vol. 156, pp. 199–207, 2014.
- [7] P. Tm, A. Pranathi, K. SaiAshritha, N. B. Chittaragi, and S. G. Koolagudi, “Tomato leaf disease detection using convolutional neural networks,” in *2018 Eleventh International Conference on Contemporary Computing (IC3)*, 2018, pp. 1–5.
- [8] Y. Kurmi, S. Gangwar, D. Agrawal, S. Kumar, and H. Shrivastava, “Leaf image analysis-based crop diseases classification,” *Signal Image and Video Processing*, vol. 00, pp. 1–8, 09 2020.
- [9] D. Hughes, M. Salathé *et al.*, “An open access repository of images on plant health to enable the development of mobile disease diagnostics,” *arXiv preprint arXiv:1511.08060*, 2015.
- [10] Teachable Machine, “Image project,” 2020. [Online]. Available: <https://teachablemachine.withgoogle.com/train>