

Classificação de Doenças em Folhas de Macieira utilizando Redes Neurais Convolucionais

Marcello Oliveira de Assis



CENTRO DE INFORMÁTICA
UNIVERSIDADE FEDERAL DA PARAÍBA

João Pessoa, PB
Novembro - 2023

Marcello Oliveira de Assis

Classificação de Doenças em Folhas de Macieira utilizando Redes Neurais Convolucionais

Trabalho de Conclusão de Curso
apresentado à Universidade Federal da
Paraíba, como requisito para a obtenção do
título de bacharelado em Ciência da
Computação.

Orientador: Tiago Maritan Ugulino de
Araújo.

João Pessoa, PB
Novembro - 2023

Catálogo na publicação
Seção de Catalogação e Classificação

A848c Assis, Marcello Oliveira de.

Classificação de doenças em folhas de macieira
utilizando redes neurais convolucionais / Marcello
Oliveira de Assis. - João Pessoa, 2023.
17 f. : il.

Orientação: Tiago Maritan Ugolino de Araújo.
TCC (Graduação) - UFPB/CI.

1. Redes Neurais. 2. Redes Convolucionais. 3.
Fitossanitário. I. Araújo, Tiago Maritan Ugolino de.
II. Título.

UFPB/CI

CDU 004

AGRADECIMENTOS

Primeiramente, gostaria de agradecer à Deus por ter me guiado por todos os percalços da vida acadêmica e por ter me sustentado até aqui.

Agradeço aos meus pais, Eunice e Marcelo, por terem dado valores que me possibilitaram chegar ao final dessa etapa da minha formação.

À minha namorada, Samantha, por todo o amor e carinho nos momentos de lamúrias que foram essenciais para me fazer perseverar no caminho para concluir essa graduação.

RESUMO

Desde de 2021, o Brasil entrou para o grupo de maiores produtores de frutos de macieiras do mundo. Entretanto, o processo de diagnóstico fitossanitário ocorre por inspeção visual que demanda treinamento especializado que elevam os custos operacionais. Logo, o presente trabalho aborda uma investigação do uso de Redes Neurais Convolucionais (CNNs) para identificar doenças em folhas de macieira, visando oferecer uma solução que pode aprimorar o processo convencional de inspeção visual, amplamente adotado nas campos agrícolas. Para treinamento dos modelos, foram utilizadas imagens disponíveis na base de dados 'New Plant Diseases Dataset'. O objetivo foi identificar se uma folha de macieira estava saudável ou não, e em caso negativo, quais dos 3 tipos de doenças presente na folha. Os resultados obtidos mostraram que o modelo obteve uma acurácia média de 83% no conjunto de teste utilizado para avaliar o modelo, além de uma precisão média de 85%, recall médio de 80% e f1-score médio de 82%.

Palavras-chave: redes neurais, redes convolucionais, fitossanitário.

ABSTRACT

Since 2021, Brazil has joined the group of the world's largest producers of apple fruits. However, the phytosanitary diagnostic process relies on visual inspection, requiring specialized training that increases operational costs. So, the following work addresses the application of Convolutional Neural Networks (CNNs) as an effective strategy to identify diseases in apple leaves, aiming to provide a solution that can replace or enhance the conventional process of visual inspection widely adopted in agricultural fields. The images used by the model were taken from the 'New Plant Diseases Dataset' available on Kaggle, resized, and subjected to a series of normalization enhancements. The goal was to identify whether an apple leaf was healthy or not, and in case of a negative diagnosis, to determine which of the three provided disease types the sample belonged to. The model achieved an accuracy of 83%, precision of 85%, recall of 80%, and f1-score of 82%.

Key-words: neural network, convolutional neural network, phytosanitary.

LISTA DE FIGURAS

Figura 1: Exemplo de folha de macieira com a doença ‘Scab’	16
Figura 2: Exemplo de folha de macieira com a doença ‘Black Rot’	16
Figura 3: Exemplo de folha de macieira com a doença ‘Cedar Rust’	16
Figura 4: Gráfico de acurácia do modelo sem pré-processamento em relação as épocas.....	16
Figura 5: Gráfico de perda do modelo sem pré-processamento em relação as épocas.....	16
Figura 6: Gráfico de acurácia do modelo com pré-processamento em relação as épocas.....	16
Figura 7: Gráfico de perda do modelo com pré-processamento em relação as épocas.....	16

LISTA DE TABELAS

Tabela 1: Matriz de confusão sem processamento.....	16
--	----

Tabela 2: Matriz de confusão com processamento.....	16
--	----

SUMÁRIO

1. Introdução.....	9
2. Trabalhos Relacionados.....	9
3. Metodologia.....	10
4. Desenvolvimento.....	11
5. Resultados.....	12
5.1. Sem Pré-Processamento.....	12
5.2. Com Pré-Processamento.....	14
6. Conclusão.....	15
Referências Bibliográficas.....	16

1. Introdução

No setor agrícola brasileiro, dentro dos diversos produtos que são oferecidos, destacam-se a produção dos frutos provenientes da macieira, que elevou o país a um dos dez maiores produtores do mundo (Silva, 2021). Este feito pode ser ainda mais

potencializado aliado-se à pesquisas científicas que tenham como intuito auxiliar no avanço da produtividade agrícola e na manutenção e melhoria dos frutos cultivados, e possivelmente proporcionar também uma redução dos custos.

A manutenção da qualidade das culturas de macieiras é crucial para a continuidade desse sucesso. Atualmente, o processo de diagnóstico fitossanitário dessas culturas é frequentemente realizado por meio de inspeção visual, onde as folhas e frutos são avaliados por especialistas.

Entretanto, a abordagem mais frequentemente utilizada, possui um grande desafio relacionado aos custos significativos que envolvem o treinamento para esses profissionais (Nachtigall et al., 2016). Tendo isso em mente, é possível pensar em soluções alternativas que sejam capazes de diminuir os custos relacionados a operação do negócio, e se possível, incrementar a precisão do processo de diagnóstico.

Deste modo, o presente trabalho almeja desenvolver uma solução que se utiliza das Redes Neurais Convolucionais (CNNs) para classificar folhas de macieira como saudáveis ou não. Além disso, quando uma folha é identificada como doente, o sistema é capaz de distinguir entre diferentes doenças, tais como *Scab*, *Black Rot* e *Cedar Rust*.

O objetivo principal do presente trabalho é desenvolver um modelo de classificação de doenças de macieira, usando redes neurais convolucionais, de forma que o modelo consiga identificar se uma folha está doente e, em caso positivo, qual o tipo de doença. Em específico, está em apresentar o uso dessas tecnologias como uma alternativa viável para o processo de diagnóstico fitossanitário.

O presente artigo está organizado da seguinte forma: na Seção 2, serão apresentados os principais trabalhos encontrados na literatura científica relacionados ao tema deste trabalho. Na Seção 3, a metodologia que foi utilizada para o desenvolvimento deste trabalho. Na Seção 4, todo o processo de desenvolvimento. Na Seção 5, os resultados obtidos do modelo. E, por fim, na Seção 6, as considerações finais acerca do artigo.

2. Trabalhos Relacionados

Até o presente momento, as soluções comerciais no Brasil com foco específico para identificação e classificação de disordens nas culturas de macieiras, se resumem à *BASF Agro app* (BASF SE, 2023) e a *Virtual Diagnose* (Embrapa Agricultura Digital, 2023).

Entretanto, existem alguns estudos voltados para identificação e classificação com foco específico em disordens de culturas de macieira. Como o trabalho de Ahil et al. (2021) onde se buscou classificar doenças em folhas de macieira e de videira, e se utilizou *Multi Layer Perceptron* (MLP) e *Convolutional Neural Networks* (CNN). Outra abordagem realizada por Sharma et al. (2023) combinou, também, Redes Neurais Convolucionais com *Long Short-Term Memory* (LSTM) para classificar múltiplas classes, onde se obteve uma acurácia de 99,02%.

Já Çetiner et al. (2021) obteve um vetor de características dos seguintes modelos: *DenseNet121*, *DenseNet201*, *InceptionResNetV2*, *InceptionV3*, *ResNet50V2* e, por fim, conectou em uma Rede Neural Convolucional e teve como resultado uma acurácia de 99%. Outro trabalho que também se utilizou de um vetor de características de modelos pré-treinados foi o do Bansal et al. (2021) onde conectou *DenseNet121*, *EfficientNetB7* e *EfficientNet NoisyStudent* e obteve uma acurácia de 90%. Liu et al. (2023) se baseou no

MobileNetV2 com uso do *ECA-Net* para construir sua solução, e tendo como resultado uma acurácia de 96,23%.

E, por fim, o trabalho de Wang et al. (2021) buscou utilizar o modelo *Coordination Attention EfficientNet* (CA-ENet) para identificar diferentes tipos de doenças em macieiras. A principal contribuição dessa abordagem foi a utilização de bloco de atenção coordenada (*coordinate attention block*) a uma rede do *EfficientNet-B4*. O modelo foi treinado 81.700 imagens e obteve uma acurácia média de 98.92%.

Estudos mais abrangentes relacionados a classificação de doenças em folhas, se destacam o trabalho de Rumpf et al. (2010) que buscava diferenciar folhas saudáveis de beterraba das doentes antes dos sintomas aparecerem. Neste trabalho, os autores reportaram uma acurácia média de 97% nessa diferenciação. Outro trabalho com foco em investigar doenças em algodão (Revathi and Hemalatha, 2014) onde se buscou, utilizando redes neurais profundas, classificar seis tipos de doenças em algodão. Neste trabalho, o modelo desenvolvido obteve uma acurácia média de 95%.

3. Metodologia

Para a criação do sistema desejado, foi utilizado a biblioteca open source Tensorflow para criação do modelo e pré-processamento de imagem. No modelo foram utilizadas duas camadas convolucionais. Na primeira camada, foram utilizados 32 filtros convolucionais, com uma máscara convolucional 3x3, com função de ativação ReLU e um filtro de *max pooling* de tamanho 2. Na camada seguinte, foram definidos 64 filtros convolucionais, outra máscara convolucional de dimensões 2x2, com função de ativação ReLU e outro filtro de *max pooling* de tamanho 2. Além disso, foram definidos o número de classes como sendo 4 (quatro) e a taxa de aprendizagem do modelo foi de 0,0004. Foi também aplicado *dropout* em 50% das unidades da camada para evitar sobreajuste e definida uma camada de saída para classificação com 4 unidades.

Como conjunto de dados para treinamento e testes para o modelo, foi utilizado a base de dados ‘New Plant Diseases Dataset’ (New Plant Diseases, 2018), disponível no Kaggle. O conjunto de dados original consiste em cerca de 87 mil imagens RGB de folhas de diversas culturas saudáveis e doentes, categorizadas em 38 classes diferentes. Essas imagens foram treinadas com e sem pré-processamento de imagens para mitigação de ruído e iluminação nas fotos. Nas Figuras 1, 2 e 3 são apresentados alguns exemplos de fotos com as respectivas doenças nas folhas de macieira.



Figura 1. Exemplo de folha de macieira com a doença ‘Scab’.



Figura 2. Exemplo de folha de macieira com a doença ‘Black Rot’.



Figura 3. Exemplo de folha de macieira com a doença ‘Cedar Rust’.

As especificações da placa de vídeo da máquina utilizada foram NVIDIA Tesla K80 with 12GB of VRAM e 2496 CUDA cores. Para avaliar o desempenho do modelo, foram utilizadas as implementações próprias da biblioteca do Tensorflow do *accuracy*, *precision*, *recall* e *f1-score*. Outra métrica utilizada foi o *loss* que é uma métrica crucial durante o treinamento, que representa a função de perda (*loss function*), que é minimizada pelo modelo durante o treinamento. A função de perda avalia a diferença entre as previsões do modelo e os rótulos verdadeiros das amostras. A ideia é minimizar essa perda para que o modelo faça previsões mais corretas.

4. Desenvolvimento

Para o presente trabalho, foi direcionado para folhas de macieira que contém 7767 fotos em relação ao conjunto original, e foram categorizados em 4 classes: uma classe correspondente a uma folha que não apresenta nenhuma doença, uma classe que indica que a folha contém a doença *Scab*, outra classe indicando que se folha possui *Black Rot* e, por fim, outra classe que visa identificar que se a folha está com a doença *Cedar Rust*. Cada classe possui 400 fotos que as representam.

Foi identificado que as imagens não estavam normalizadas, de forma que possuíam diferentes graus de ruídos e variações de luminosidade. Para isso foi realizado um pré-processamento prévio ao treinamento do modelo. Foi utilizada a classe ImageDataGenerator da biblioteca do Tensorflow para normalizar os pixels e aplicar variações de rotação nas imagens para incrementar a variedade de dados de treinamento, o que pode levar o modelo a prever uma diversidade maior de imagens e levar o modelo à um melhor desempenho. Além disso, as imagens foram redimensionadas para proporcionar um menor tempo de execução no ambiente do Google Colab.

Dessa forma, foi realizado o treinamento do modelo utilizando os seguintes parâmetros: as dimensões da imagem de entrada foram redimensionadas e, por fim, foram estabelecidas como 150x150 pixels, e o tamanho do lote (*batch_size*) usado durante o treinamento foi definido como 32. Foram 1000 amostras por época por treinamento, 13 passos de validação (que indicam a frequência da validações durante o treinamento). O histórico do desempenho do treinamento contendo as informações sobre a precisão e a perda ocorrida durante cada iteração das épocas foi gerado de forma a possibilitar uma análise por meio de gráficos.

O processo foi repetido novamente, diferindo-se do processo anterior somente pela ausência de processamento de imagens para possibilitar uma análise acerca da contribuição efetiva que o pré-processamento teria no desempenho do modelo estabelecido.

5. Resultados

Os resultados referentes ao desempenho do modelo foram divididos em duas subseções. Ao final desta seção constará a análise referente ao impacto dessa intervenção na eficácia. A Seção 5.1 tem por objetivo examinar o desempenho do modelo quando não submetido ao pré-processamento de imagens descrito na Seção 4.

5.1. Sem Pré-Processamento

Figura 4. Gráfico de acurácia do modelo sem pré-processamento em relação as épocas.




Figura 5. Gráfico de perda do modelo sem pré-processamento em relação as épocas.




Tabela 1. Matriz de confusão sem processamento

	Scab	Black Rot	Cedar Rust	Healthy
Scab	26	43	27	4
Black Rot	1	97	2	0
Cedar Rust	0	0	100	0
Healthy	1	9	11	79

As métricas para avaliação desse modelo apresentaram os seguintes números: a acurácia no conjunto de dados de treinamento foi de 93% enquanto nos dados de teste foram de 84%. A precisão encontrada durante o treinamento foi de 95% e de 87% na teste. O recall foi de 80% para os dados de teste, enquanto o de treinamento foi de 90%. A métrica f1-score foi de 84% para o conjunto de teste e 93% para o conjunto de treinamento.

5.2. Com Pré-Processamento

Figura 6. Gráfico de acurácia do modelo com pré-processamento em relação as épocas.




Figura 7. Gráfico de perda do modelo com pré-processamento em relação as épocas.




Tabela 2. Matriz de confusão com processamento

	Scab	Black Rot	Cedar Rust	Healthy
Scab	28	62	8	2
Black Rot	0	100	0	0
Cedar Rust	0	3	96	1
Healthy	2	26	0	72

As métricas para avaliação desse modelo apresentaram os seguintes números: a acurácia no conjunto de dados de treinamento foi de 89% enquanto nos dados de teste foram de 82%. A precisão encontrada durante o treinamento foi de 91% e de 84% na teste. O *recall* foi de 80% para os dados de teste, enquanto o de treinamento foi de 87%. A métrica *f1-score* foi de 81% para o conjunto de teste e 88% para o conjunto de treinamento.

Analisando os dados fornecidos acima, é possível afirmar que as métricas de avaliação mostram que o modelo após a implementação do pré-processamento para mitigação de ruído e otimização da iluminação nas imagens, apresentou um desempenho notavelmente superior. Além disso, os resultados obtidos durante o treinamento ocorreram em um número significativamente reduzido de ciclos.

Além disso, a quantidade de *loss* associados as mesmas amostras seguiram uma tendência relativamente semelhante. Portanto, pode-se concluir que o pré-processamento de mitigação de ruído e aprimoramento da iluminação tiveram um impacto positivo na eficácia do modelo, permitindo uma maior precisão e uma redução

substancial na quantidade de ciclos necessários para alcançar tais resultados satisfatórios.

6. Conclusões

A partir dos resultados apresentados, podemos concluir que a utilização de Redes Convolucionais no contexto de detecção de doenças em folhas de macieiras originou bons resultados e se apresenta como uma alternativa viável para o processo de diagnóstico fitossanitário manual que é mais comumente empregado nos dias atuais.

No entanto, este trabalho abre portas para investigações e aprimoramentos futuros. Um dos passos primordiais que se pode fazer para tornar o sistema mais robusto, seria incluir um número maior de classes de doenças, buscando categorizar de acordo com as disordens de culturas de macieiras de maior relevância no Brasil para assim garantir uma maior adaptabilidade ao contexto agrícola nacional. Além disso, se pode optar pela utilização do modelo *CA-ENet*, implementando as adaptações necessárias, vide a acurácia obtida, pois isso possibilitaria a incorporação dessa solução em sistemas de drones ou dispositivos móveis que possuem um custo de manutenção e operacional melhor que a implementação em outros sistemas mais complexos.

Referências Bibliográficas

Silva, E. 2021. “Com safra de mais de 1 milhão de toneladas, Brasil é um dos 10 maiores produtores mundiais de maçã”. Globo. Disponível em: <<https://globo rural.globo.com/Noticias/Agricultura/Hortifruti/noticia/2021/12/com-safra-de-mais-de-1-milhao-de-toneladas-brasil-e-um-dos-10-maiores-produtores-mundiais-de-maca.html>> Acesso em: 20 de outubro de 2023.

Nachtigall, L. Araujo, M. Nachtigall, G. 2016. “Classification of Apple Tree Disorders Using Convolutional Neural Networks”. IEEE.

BASF SE. 2023. “BASF Agro app”. BASF. Disponível em: <<https://agriculture.basf.com/br/pt/protecao-de-cultivos-e-sementes/servicos/agro-app.html>> Acesso em: 20 de outubro de 2023.

Embrapa Agricultura Digital. 2023. “Diagnose Virtual”. Embrapa. Disponível em: <<https://www.diagnose.cnptia.embrapa.br/diagnose/>> Acesso em: 20 de outubro de 2023.

Ahil, M. Vanitha, V. Rajathi, N. 2021. “Apple and Grape Leaf Disease Classification using MLP and CNN”. IEEE.

Sharma, R. Kukreja, V. Sood, P. Bhattacharjee, A. 2023. “Classifying the Severity of Apple Black Rot Disease with Deep Learning: A Dual CNN and LSTM Approach”. IEEE.

Kimliği, Y. 2021. “Classifying of Apple Leaf Diseases using Convolutional Neural Network approach”. Journal of Engineering Sciences and Design.

Bansal, P. Kumar, R. Kumar, S. 2021. "Disease Detection in Apple Leaves Using Deep Convolutional Neural Network". Agriculture 11, p. 7-617.

Liu, S. Bai, H. Li, F. Wang, D. Zheng, Y. Jiang, Q. Sun, F. 2023. "An apple leaf disease identification model for safeguarding apple food safety". Food Science and Technology.

Wang, P. Tong, N. Mao, Y. Zhang, Z. Liu, B. He, D. 2021. "Identification of Apple Leaf Diseases by Improved Deep Convolutional Neural Networks With an Attention Mechanism". Sec. Technical Advances in Plant Science.

Rumpf, T. Mahlein, A.K. Steiner, U. Oerke, E.C. Dehne, H.W. Plumer, L. 2010. 74(1):91–99. "Early detection and classification of plant diseases with support vector machines based on hyperspectral reflectance. Computers and Electronics in Agriculture".

Revathi, P. Hemalatha, M. 2014. "Identification of cotton diseases based on cross information gain deep forward neural network classifier with pso feature selection.". International Journal of Engineering and Technology (IJET) ISSN.

Kaggle, New Plant Diseases, 2018, Disponível em:

<<https://www.kaggle.com/datasets/vipooool/new-plant-diseases-dataset/data>> Acesso em: 8 de dezembro de 2022.