

GRASIELLI BARRETO ZIMMERMANN

Classificação Automática de Doenças no Cultivo de Tomate em Estufas

Curitiba - PR, Brasil

2024

GRASIELLI BARRETO ZIMMERMANN

Classificação Automática de Doenças no Cultivo de Tomate em Estufas

Tese apresentada ao Programa de Pós-Graduação em Informática da Pontifícia Universidade Católica do Paraná como requisito parcial para obtenção do título de doutor em Informática.

Pontifícia Universidade Católica do Paraná - PUCPR

Programa de Pós-Graduação em Informática - PPGIa

Orientador: MARCELO EDUARDO PELLEZ

Coorientador: ALCEU DE SOUZA BRITTO JR.

Curitiba - PR, Brasil

2024

Dados da Catalogação na Publicação
Pontifícia Universidade Católica do Paraná
Sistema Integrado de Bibliotecas – SIBI/PUCPR
Biblioteca Central
Luci Eduarda Wielganczuk – CRB 9/1118

Z73c
2024

Zimmermann, Grasielli Barreto

Classificação automática de doenças no cultivo de tomate em estufas /
Grasielli Barreto Zimmermann ; orientador: Marcelo Eduardo Pellenz ;
coorientador: Alceu de Souza Britto Jr. – 2024.
74 f. : il. ; 30 cm

Tese (doutorado) – Pontifícia Universidade Católica do Paraná, Curitiba,
2024

Bibliografia: f. 68-74

1. Informática. 2. Sistema de reconhecimento de padrões. 3. Agricultura
de precisão. 4. Agricultura – Processamento de dados. 5. Tomate – Doenças e
pragas – Classificação – Processamento de dados. 6. Estufas. I. Pellenz,
Marcelo Eduardo. II. Britto Junior, Alceu de Souza. III. Pontifícia Universidade
Católica do Paraná. Programa de Pós-Graduação em Informática. IV. Título.

CDD 20. ed. – 004

Curitiba, 29 de novembro de 2024.

96-2024

DECLARAÇÃO

Declaro para os devidos fins, que **GRASIELLI BARRETO ZIMMERMANN** defendeu a tese de Doutorado intitulada “**Classificação Automática de Doenças no Cultivo de Tomate em Estufas**”, na área de concentração Ciência da Computação no dia 08 de novembro de 2024, no qual foi aprovada.

Declaro ainda, que foram feitas todas as alterações solicitadas pela Banca Examinadora, cumprindo todas as normas de formatação definidas pelo Programa.

Por ser verdade firmo a presente declaração.

Documento assinado digitalmente
 **EMERSON CABRERA PARAISO**
Data: 29/11/2024 13:54:46-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Emerson Cabrera Paraiso
Coordenador do Programa de Pós-Graduação em Informática

AGRADECIMENTOS

Ao decidir me dedicar ao Doutorado, tinha apenas uma noção vaga das dificuldades que enfrentaria, mas não podia imaginar plenamente o quão desafiadora essa jornada seria. Felizmente, ao longo desse percurso, encontrei pessoas e instituições que tornaram o processo mais leve e significativo, oferecendo apoio, incentivo e companheirismo nos momentos mais cruciais.

Agradeço, em primeiro lugar, a Deus, por estar ao meu lado em todos os momentos, sejam eles bons ou desafiadores.

Ao meu orientador, Prof. Dr. Marcelo E. Pellenz, expresso minha mais profunda gratidão. Tenho plena certeza de que, sem o seu apoio, não teria chegado até aqui. Agradeço por compartilhar generosamente seu conhecimento, e por sua compreensão, paciência e amizade ao longo de toda essa jornada.

Ao meu coorientador, Prof. Dr. Alceu De Souza Britto Jr., e ao Prof. Yandre M. G. Costa, deixo meu sincero agradecimento por toda a colaboração e dedicação a esta pesquisa. A contribuição de ambos foi fundamental para a concretização deste trabalho.

Agradeço também à Pontifícia Universidade Católica do Paraná, por me acolher tão bem durante todos esses anos, e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro, que foi essencial para o desenvolvimento deste estudo.

Aos agricultores, que gentilmente me permitiram acessar suas propriedades para coletar as imagens necessárias, meu muito obrigado por sua confiança e disponibilidade.

Por fim, agradeço de coração à minha família pelo constante incentivo, apoio e compreensão. Em especial, ao meu esposo e ao meu filho, por serem minha maior fonte de força e motivação durante essa jornada.

Obrigada!!

Para Leo e João

*Nosso Senhor e nosso Deus, tu és digno de receber a glória, a honra e o poder, porquanto
tu és o Criador de tudo e, por tua soberana vontade, tudo o que há, foi criado e veio a
existir. Apocalipse 4:11*

RESUMO

Contexto: O crescimento populacional gera um aumento proporcional na demanda por alimentos. Nesse cenário, as doenças em plantas representam uma barreira significativa e um desafio para a obtenção de maior produtividade e qualidade na produção agrícola. A agricultura de precisão tem sido cada vez mais aplicada para otimizar o manejo das culturas. Neste contexto, a *Internet das Coisas* (IoT) tem se destacado como uma facilitadora essencial, permitindo diversos tipos de monitoramento no campo. Os cultivos estão suscetíveis a uma ampla variedade de doenças, que atualmente dependem em grande parte do uso de agrotóxicos. Essa abordagem pode ser extremamente prejudicial à saúde humana e impacta negativamente o meio ambiente. O tomate, uma das hortaliças mais consumidas no mundo, pode ser cultivado em estufas para consumo *in natura* ou em campo aberto voltado para o mercado ou a indústria. Para o consumo *in natura*, um dos requisitos mais importantes é que os frutos tenham uma apresentação adequada para a venda, o que exige monitoramento constante e ações eficazes para evitar que doenças comprometam sua qualidade. **Objetivo:** O objetivo deste trabalho de pesquisa foi desenvolver uma técnica para a detecção e classificação de doenças no cultivo do tomate em estufa. A proposta é utilizar técnicas de aprendizado de máquina para analisar imagens das folhas das plantas, proporcionando um apoio ao diagnóstico preciso e rápido sobre o tipo de doença presente. **Metodologia:** Algumas regiões do Paraná são referências no cultivo de tomate em estufa. Neste estudo, coletamos e criamos um conjunto de dados com imagens de doenças específicas que ocorrem no tomateiro em estufa nessa região. Com esse novo conjunto de dados, exploramos técnicas de aprendizado profundo para desenvolver uma estratégia eficaz de classificação dessas doenças. **Resultados:** Os resultados foram obtidos por meio de três abordagens: uma específica, utilizando Redes Neurais Convolucionais, e duas outras que empregaram redes pré-treinadas, VGG19 e ResNet50. Essas abordagens foram avaliadas tanto individualmente como em conjunto. As estratégias foram testadas com dois tamanhos de imagens: uma com a folha inteira e outra com partes contaminadas. Apesar de algumas confusões entre as classes de doenças, especialmente nas folhas com múltiplas patologias vegetais, os resultados destacam o potencial das redes em diferenciar doenças em condições complexas. **Conclusão:** Este projeto de pesquisa aborda um contexto específico e relevante na produção de tomate. Um novo conjunto de dados de imagens de folhas foi coletada e processada especificamente para este estudo, por meio de visitas a uma importante região produtora no Paraná. Com base nos estudos realizados, pretendemos aprimorar as estratégias de identificação, visando melhorar o desempenho dos métodos e desenvolver uma solução útil para os produtores.

Palavras-chave: Agricultura de Precisão, Cultivo de Tomate, Estufas, Classificação de Doenças, Reconhecimento de Padrões, CNN.

ABSTRACT

Context: Population growth generates a proportional increase in food demand. In this scenario, plant diseases represent a significant barrier and a challenge to achieving higher productivity and quality in agricultural production. Precision agriculture has been increasingly applied to optimize crop management. In this context, the Internet of Things (IoT) has emerged as an essential enabler, allowing various types of field monitoring. Crops are susceptible to a wide variety of diseases, which currently rely heavily on the use of pesticides. This approach can be extremely harmful to human health and negatively impacts the environment. Tomato, one of the most consumed vegetables worldwide, can be cultivated in greenhouses for fresh consumption or in open fields for the market or industry. For fresh consumption, one of the most important requirements is that the fruits have an adequate appearance for sale, which requires constant monitoring and effective actions to prevent diseases from compromising their quality. **Objective:** The objective of this research was to develop a technique for detecting and classifying diseases in greenhouse tomato cultivation. The proposed method involves using machine learning techniques to analyze plant leaf images, providing precise and rapid support for diagnosing the type of disease present. **Methodology:** Some regions of Paraná are reference areas for greenhouse tomato cultivation. In this study, we collected and created a dataset with images of specific diseases that occur in greenhouse tomatoes in this region. With this new dataset, we explored deep learning techniques to develop an effective strategy for classifying these diseases. **Results:** The results were obtained through three approaches: one specific, using Convolutional Neural Networks, and two others employing pre-trained networks, VGG19 and ResNet50. These approaches were evaluated both individually and in combination. The strategies were tested with two image sizes: one with the entire leaf and another with contaminated sections. Despite some confusion between disease classes, especially in leaves with multiple plant pathologies, the results highlight the potential of the networks to differentiate diseases under complex conditions. **Conclusion:** This research project addresses a specific and relevant context in tomato production. A new dataset of leaf images was collected and processed specifically for this study through visits to a key production region in Paraná. Based on the studies conducted, we aim to improve identification strategies, enhance the methods' performance, and develop a useful solution for producers.

Keywords: Precision Agriculture, Tomato Cultivation, Greenhouses, Disease Classification, Pattern Recognition, CNN.

LISTA DE ILUSTRAÇÕES

Figura 1 – Exemplo de uma folha saudável e folhas doentes.	18
Figura 2 – Localização do município de Faxinal, grande produtor de tomate em estufas no Paraná.	19
Figura 3 – Métodos de Votação.	40
Figura 4 – Fatores que determinam a intensidade da doença no tomateiro.	41
Figura 5 – Ramos do tomateiro infectado com doenças.	47
Figura 6 – Folhas Saudáveis com influência de sombras na imagem.	48
Figura 7 – Diferentes tipos de ataques da Mosca Minadora.	49
Figura 8 – Evolução da doença Mancha Bacteriana.	49
Figura 9 – Evolução da doença Oídio.	49
Figura 10 – Combinação de duas doenças Oídio e Minadora.	49
Figura 11 – Combinação de duas doenças Mancha Bacteriana e Minadora.	50
Figura 12 – Mosca Branca, inseto transmissor do Mosaico-dourado-do-tomateiro.	50
Figura 13 – Diferentes tamanhos de imagens usadas no método proposto.	50
Figura 14 – Patches Saudáveis.	50
Figura 15 – Patches Minadora.	51
Figura 16 – Patches Mancha Bacteriana.	51
Figura 17 – Patches Oídio.	51
Figura 18 – Patches Oídio e Minadora.	51
Figura 19 – Patches Mancha Bacteriana e Minadora.	51
Figura 20 – Patches Mosca Branca.	51
Figura 21 – Patches Fundo da imagem.	52
Figura 22 – Diagrama de blocos do método proposto.	53
Figura 23 – A arquitetura do modelo CNN customizado.	53
Figura 24 – Arquitetura de rede VGG19.	56
Figura 25 – Arquitetura Resnet50.	56
Figura 26 – Métodos utilizados para classificação de doenças do tomateiro.	58
Figura 27 – Diagrama de blocos do Método A.	59
Figura 28 – Matriz de confusão Método A - CNN.	61
Figura 29 – Matriz de confusão Método A - VGG19.	62
Figura 30 – Matriz de confusão Método A - Resnet50.	62
Figura 31 – Matriz de confusão Método B - CNN.	63
Figura 32 – Matriz de confusão Método B - VGG19.	64
Figura 33 – Matriz de confusão Método B - Resnet50.	64

Figura 34 – Diagrama de blocos de detecção e classificação de doenças foliares locais do tomateiro.	65
Figura 35 – Exemplos de classificação de imagens usando o Método B.	66

LISTA DE TABELAS

Tabela 1 – Estudos que utilizaram Machine Learning para classificação de doenças no tomate.	30
Tabela 2 – Matriz de confusão.	39
Tabela 3 – Principais doenças do tomateiro.	42
Tabela 4 – Número de imagens por classe PlantVillage para doenças do Tomate. .	45
Tabela 5 – Número de imagens por Classe.	48
Tabela 6 – Número de patches por classe.	52
Tabela 7 – F-score de redes profundas usando dataset TLID (%)	59
Tabela 8 – Resultados dos classificadores individuais Método A e PlantVillage. . .	60
Tabela 9 – Resultados dos classificadores por Votação Método A.	60
Tabela 10 – Resultados dos classificadores individuais Método B.	63
Tabela 11 – Resultados dos classificadores por Votação Método B.	63

LISTA DE ABREVIATURAS E SIGLAS

Adagrad	Adaptive Gradient Algorithm
Adam	Adaptive Moment Estimation
ANN	Artificial Neural Network
CART	Classification and Regression Trees
CNN	Convolutional Neural Network
ELU	Exponential Linear Unit
FAO	Food and Agriculture Organization
GCP	Google Cloud Platform
HOG	Histogram of Oriented Gradient
IA	Inteligência Artificial
IoT	Internet of Things
JPG	Joint Photographic Experts Group
KNN	K-Nearest Neighbour
LeakyReLU	Leaky Rectified Linear Unit
LVQ	Learning Vector Quantization
ML	Machine Learning
NN	Neural Network
ONU	Organização das Nações Unidas
PTLID	Patch-based Tomato Leaf Image Dataset
RFID	Radio-Frequency Identification
RGB	Red, Green, Blue
ReLU	Rectified Linear Unit
RMSPROP	Root Mean Square Propagation

RNN	Recurrent Neural Network
SGD	Stochastic Gradient Descent,
SVM	Support Vector Machine
TLID	Tomato Leaf Image Dataset
VGG	Visual Geometry Group
Xception	Extreme Inception
YOLO	You Only Look Once

LISTA DE SÍMBOLOS

Ca^{2+}	Cálcio
FP	falsos positivos
FN	falsos negativos
i	classificador
K	Potássio
N	Nitrogênio
P	precisão
p_i	probabilidade das classes
P_k	probabilidade de pertencer a classe k
P	precisão
R	recall
TP	verdadeiros positivos
TN	verdadeiros negativos
y_i	categoria prevista para cada classe
y	categoria final

SUMÁRIO

1	INTRODUÇÃO	17
1.1	Motivação	20
1.2	Objetivos	21
1.3	Estrutura do Documento	21
2	TRABALHOS RELACIONADOS	22
2.1	Introdução	22
2.2	Agricultura IoT	22
2.3	Técnicas para Classificação de Doenças em Plantas	23
2.4	Técnicas para Classificação de Doenças no Tomate	25
2.5	Considerações Finais	29
3	FUNDAMENTAÇÃO TEÓRICA	31
3.1	Aprendizagem de Máquina	31
3.2	Redes Neurais	32
3.3	Aprendizado Profundo	33
3.3.1	Redes Neurais Convolucionais	34
3.3.2	Arquitetura CNN	34
3.3.3	VGG-19	35
3.3.4	Resnet50	36
3.4	<i>Overfitting</i>	36
3.5	Data Augmentation	37
3.6	Técnica de Regularização	37
3.7	Métricas de Avaliação	37
3.8	Support Vector Machine - SVM	39
3.9	Ensemble Voting	39
3.10	Doenças de Plantas	41
3.10.1	Oídio	42
3.10.2	Mancha Bacteriana	43
3.10.3	Mosaico-dourado-do-tomateiro	43
3.10.4	Minadora	44
3.11	Bases de Dados PlantVillage	44
3.12	Considerações Finais	45
4	MODELO DE SISTEMA	46
4.1	Conjunto de Dados	46

4.1.1	Conjunto de dados de imagens de folhas do tomate (Tomato Leaf Image Dataset (TLID))	46
4.1.2	Conjunto de dados de Patches de folhas do tomate (Patch-based Tomato Leaf Image Dataset (PTLID))	48
4.2	Método Proposto	52
4.2.1	CNN modelo customizado	52
4.2.2	Modelo VGG19	55
4.2.3	Modelo Resnet50	55
4.3	Considerações Finais	56
5	RESULTADOS	58
5.0.1	Método A	58
5.0.2	Método B	61
5.1	Considerações Finais	66
6	CONCLUSÃO E TRABALHOS FUTUROS	68
	REFERÊNCIAS	69

1 INTRODUÇÃO

A Organização das Nações Unidas (ONU) projeta que a população mundial ultrapassará 11 bilhões de pessoas até o final do século ([NATIONS, 2022](#)). Nesse contexto, a questão alimentar se torna fundamental, uma vez que o crescimento populacional resulta em aumento na demanda por água, alimentos e energia. Um dos principais desafios da agricultura para aumentar a produção é o controle de doenças em plantas, que podem comprometer tanto a produtividade quanto a qualidade dos alimentos.

A agricultura de precisão tem se consolidado como uma solução eficaz para otimizar o manejo agrícola e aumentar a produtividade. Essa abordagem pode ser aplicada em diversas práticas, como o monitoramento do solo, o controle de rebanhos, a irrigação e o monitoramento de plantações, entre outras ([PERNAPATI, 2018](#); [KAYETHA; PABBOJU, 2020](#); [TANEJA et al., 2018](#); [KITPO et al., 2019](#)).

A Internet das Coisas (*Internet of Things* - IoT) desempenha um papel essencial nesse processo, facilitando a medição e o controle de diversos parâmetros no campo, o que resulta em melhorias significativas na produtividade ([FAROOQ et al., 2019](#)) ([NAVARRO; COSTA; PEREIRA, 2020](#)) ([KHANNA; KAUR, 2019](#)). No gerenciamento de estufas, por exemplo, a IoT pode ser utilizada para monitorar a necessidade de irrigação para o crescimento das plantas, controlar a umidade do ar e do solo, além de identificar doenças nas culturas ([VELASCO; FONTHAL; L., 2018](#); [PITAKPHONGMETHA et al., 2016](#); [KHAN; ABUBAKAR; ZEKI, 2020](#)).

As lavouras estão vulneráveis a uma ampla variedade de doenças, que podem ser definidas como quaisquer anormalidades causadas por fatores bióticos ou abióticos que afetam de forma contínua o metabolismo das plantas. Essas doenças frequentemente resultam em redução da produtividade e/ou perda de qualidade dos produtos, podendo, inclusive, manifestar-se após a colheita e torná-los inadequados para o consumo ([LOPES; AVILA, 2005](#)).

Um dos fatores que pode influenciar o surgimento de doenças nas plantas é o clima ([GHINI R., 2011](#)). As mudanças climáticas afetam variáveis regionais essenciais, como umidade, temperatura e precipitação, criando condições favoráveis para que patógenos, vírus e pragas destruam culturas ([ANGELOTTI F.; BETTIOL, 2017](#)). Isso gera impactos diretos para a população, incluindo consequências econômicas, de saúde e na subsistência das comunidades ([BOULEY et al., 2014](#)). Para combater essas doenças, frequentemente são utilizados agrotóxicos, que, embora eficazes, podem ser prejudiciais à saúde humana e causar danos significativos ao meio ambiente. Nesse contexto, a agricultura de precisão surge como uma alternativa promissora, permitindo a identificação de doenças nas plantas

de forma mais precisa e reduzindo a necessidade da aplicação desses insumos químicos.

O tomate é uma das hortaliças mais consumidas no mundo, cultivado de duas formas principais: em campo aberto, destinado tanto ao consumo *in natura* quanto à indústria de molhos e extratos, e em estufas, que possibilitam o cultivo durante todo o ano. O cultivo em estufa requer que os frutos tenham uma apresentação adequada para a venda, o que torna essencial o monitoramento constante das plantas para evitar que pragas ou doenças comprometam sua qualidade. Esse monitoramento geralmente é realizado por profissionais especializados, que podem utilizar ou não testes laboratoriais para diferenciar as doenças. No total, cerca de duzentas doenças e distúrbios fisiológicos já foram identificados na tomaticultura em todo o mundo (LOPES; AVILA, 2005).

As folhas de tomate cultivadas em estufas, ao contrário das cultivadas a céu aberto, não são lavadas pela água da chuva ou por métodos de irrigação. Isso resulta no acúmulo de partículas, poeira e resíduos de fertilizantes em sua superfície. A Figura 1 apresenta imagens de folhas de tomate saudáveis e de folhas afetadas por diferentes doenças, bem como combinações dessas doenças.




Figura 1 – Exemplo de uma folha saudável e folhas doentes.

Segundo estatísticas da *Food and Agriculture Organization - FAO*, aproximadamente 170 milhões de toneladas de tomates frescos e processados foram produzidas globalmente em 2014 (LEITE; FIALHO, 2018). No Brasil, a produção alcançou 4,0 milhões de toneladas em 2021 (IBGE, 2021), com o estado do Paraná contribuindo com 215.400 toneladas.

Faxinal, localizada ao norte do Paraná conforme indicado no mapa da Figura 2, é reconhecida como a Capital do Tomate em Estufa do Estado, conforme a Lei Estadual nº



Figura 2 – Localização do município de Faxinal, grande produtor de tomate em estufas no Paraná.

17.224/2012. O solo da região é predominantemente composto por Terra Roxa, conhecido por suas excelentes condições para a agricultura. O clima é subtropical úmido, com chuvas concentradas no verão, especialmente acima do paralelo 24° Sul, e sem uma estação seca definida. A temperatura média anual é de 19°C, com máximas de 23°C e mínimas de 15°C. Essa combinação favorável de solo e clima torna a região ideal para o cultivo de tomates em estufa. A produtividade do tomate tem impulsionado a economia local, com uma produção de 14.000 toneladas no último ano. Com visitas as propriedades realizadas no ano de 2020, constatou-se que as doenças mais comuns influenciadas pelo clima nesse período foram Mancha Bacteriana, Minadora, Oídio e Mosca Branca. O acesso às estufas de tomate foi realizado com o consentimento dos produtores, o que possibilitou a coleta de imagens para criar o conjunto de dados.

No município, há uma diversidade de produtores, tanto grandes quanto pequenos, com uma predominância de propriedades administradas por famílias que contam com poucos funcionários. O cultivo de tomates é beneficiado pela temperatura amena da região, que possui numerosos rios, garantindo a irrigação adequada dos canteiros. Embora a região tenha uma tradição no cultivo de tomates a céu aberto, as frequentes chuvas tornaram esse método problemático.

De acordo com a Secretaria de Agricultura do Município, estima-se que existam cerca de 700 estufas na área. Além disso, a localização geográfica da cidade é um fator crucial, permitindo que os produtos sejam rapidamente entregues aos grandes centros de distribuição de alimentos.

Considerando que o ambiente de estufa favorece o desenvolvimento de doenças específicas, diferentes daquelas que ocorrem em campo aberto e também que variam entre regiões devido a fatores climáticos. Propomos, neste estudo, um método específico para reconhecer doenças no cultivo de tomate em ambientes de estufas com foco regional. Há uma carência de conjunto de dados específicos com imagens de doenças associadas ao cultivo de tomate em estufas. Este cenário de cultivo apresenta peculiaridades quanto aos tipos e características de doenças que podem estar presentes no tomate.

Por meio deste estudo, pretendemos responder às seguintes questões de pesquisa:

- Q1: As doenças presentes no cultivo de tomate em estufa apresentam especificidades regionais?
- Q2: Como os algoritmos de identificação se comportam usando imagens não processadas coletadas por smartphones?
- Q3: É possível aumentar a precisão na identificação de doenças combinando algoritmos de aprendizado de máquina?
- Q4: É possível identificar a presença de múltiplas doenças em folhas de tomate e seu grau de contaminação usando estratégias baseadas em aprendizado de máquina?

1.1 Motivação

A detecção e identificação de doenças em plantas são fundamentais para a implementação de medidas de controle eficazes. Essa necessidade é impulsionada pela demanda por alimentos mais saudáveis, redução dos custos de produção e preservação ambiental. Normalmente, a primeira identificação de uma doença é realizada pelo agricultor, que muitas vezes não consegue determinar com precisão o tipo de doença, necessitando assim da ajuda de um profissional especializado. Este especialista pode optar por realizar ou não testes laboratoriais, uma vez que algumas doenças apresentam sintomas muito semelhantes.

A motivação para esta pesquisa é aprimorar a identificação de doenças e pragas em estufas de tomate. Existem diversas doenças e pragas que afetam o tomate, e sua ocorrência é influenciada pelas condições climáticas de cada região. Embora já existam estudos que utilizam redes neurais para detectar doenças no tomate, os conjuntos de dados mais frequentemente empregados na literatura abordam apenas doenças de uma região específica. Além disso, essas bases não consideram a possibilidade de múltiplas doenças e pragas afetando uma mesma folha simultaneamente.

1.2 Objetivos

O objetivo principal deste trabalho é utilizar técnicas de aprendizagem profunda, especificamente redes neurais convolucionais (*Convolutional Neural Networks* - CNNs) e Votação em Conjunto, para identificar doenças e pragas em tomates cultivados em estufas, com um novo conjunto de dados obtido em uma região específica. A solução proposta não apenas considerará novas doenças, mas também levará em conta a possibilidade de uma planta ser afetada simultaneamente por mais de uma doença. Os objetivos específicos são:

1. Realizar uma revisão bibliográfica sobre estudos anteriores que abordam a identificação de doenças e pragas no cultivo do tomate.
2. Coletar imagens de doenças e pragas em tomates em campo, focando na produção regional em estufas no município de Faxinal.
3. Executar o pré-processamento das imagens e criar um novo conjunto de dados.
4. Propor e implementar métodos de reconhecimento de doenças e pragas do tomate utilizando técnicas de aprendizagem de máquina.
5. Avaliar o desempenho dos métodos propostos.

1.3 Estrutura do Documento

Este documento está estruturado da seguinte forma: O Capítulo 2 apresenta e discute os trabalhos relacionados à pesquisa. O Capítulo 3 aborda os conceitos fundamentais relacionados a aprendizagem de máquina e as principais doenças associadas ao cultivo do tomate e suas características. O Capítulo 4 detalha a formação do conjunto de dados, incluindo as doenças e pragas coletadas, bem como suas quantidades. Além disso, são apresentadas e descritas as arquiteturas das redes CNN, VGG19 e ResNet50, junto com os parâmetros utilizados em cada uma delas. No Capítulo 5, são apresentados os resultados dos métodos selecionados, com uma análise comparativa entre eles, além de discussões sobre as propostas para os próximos passos. Por fim, o Capítulo 6 traz as conclusões do trabalho.

2 TRABALHOS RELACIONADOS

2.1 Introdução

Este capítulo analisa pesquisas relevantes sobre a identificação de doenças em plantas, utilizando aprendizado de máquina e aprendizado profundo. Para atingir os objetivos desta investigação, foi realizada uma revisão da literatura atual, abrangendo fontes como a internet, livros, artigos e periódicos. O intuito foi identificar lacunas nas soluções existentes que possam ser abordadas pela proposta deste estudo. A análise está organizada em quatro seções. A Seção 2.2 explora como a agricultura IoT pode ser aplicada para otimizar e agilizar processos agrícolas. Apresenta aplicações práticas, como o monitoramento de umidade, erosão e fertilidade do solo, além da gestão hídrica por meio de sistemas de irrigação inteligente. A Seção 2.3 discute as técnicas utilizadas na classificação de doenças de plantas e os resultados obtidos, destacando abordagens de aprendizado de máquina e aprendizado profundo. A Seção 2.4 descreve as técnicas de aprendizado profundo aplicadas à detecção de doenças no cultivo de tomate. Esta seção também apresenta os resultados obtidos com a base de dados mais utilizada na literatura, além de algumas referências a doenças que não estão incluídas nessa base.

2.2 Agricultura IoT

A Internet das Coisas é um campo emergente que integra diversas tecnologias de *Software* e dispositivos de *Hardware*, como telecomunicações sem fio, sensores, etiquetas RFID (*Radio-Frequency Identification*), telefones celulares, entre outros. O termo “Internet das Coisas” foi inventado por Kevin Ashton em 1999. A palavra “coisas” refere-se aos diferentes objetos interconectados, enquanto “internet” indica que esses objetos estão conectados à rede.

A capacidade de conectar uma variedade de elementos como animais, pessoas, veículos, ambientes e eletrodomésticos possibilita a aplicação dessa tecnologia em diversos contextos, incluindo a agricultura. Na agricultura IoT, essas conexões permitem o monitoramento e a gestão eficiente de recursos, contribuindo para uma produção mais sustentável e otimizada.

A agricultura desempenha um papel vital para a humanidade, especialmente com o crescimento populacional que aumenta a demanda por alimentos. A *Internet das Coisas* (IoT) tem sido amplamente aplicada para otimizar diversos processos agrícolas, visando não apenas o aumento da produção, mas também a melhoria da qualidade dos alimentos.

Com a agricultura inteligente, as medições são realizadas de forma mais ágil e eficiente. Por meio de sensores integrados a essa tecnologia, é possível monitorar uma variedade de parâmetros, como as condições do solo, da água, do ar, o estado das plantas, o manejo de rebanhos e as variáveis climáticas, entre outros. Isso resulta em gestão mais precisa e sustentável dos recursos agrícolas.

Um exemplo do uso da IoT na agricultura é a avaliação contínua e precisa da qualidade do solo, que tradicionalmente depende de departamentos e técnicos especializados. As características dos talhões (áreas de cultivo) podem variar significativamente, incluindo fatores como umidade do solo, fertilidade e erosão.

Na pesquisa de (SPANDANA; PABBOJU, 2020), foi realizado um monitoramento da qualidade do solo por meio de sensores que mediram o tipo de solo, a evapotranspiração e os níveis de umidade. Essa abordagem permitiu determinar, por exemplo, a quantidade exata de água necessária para cada talhão específico, bem como a quantidade de fertilizantes requerida para a área em análise. As informações coletadas foram armazenadas na nuvem para uso posterior. Com base nessa análise, o agricultor pode tomar decisões sobre quais culturas se adaptam melhor a cada tipo de solo.

A água é uma preocupação central na agricultura, devido à sua escassez e ao elevado consumo associado. Muitas vezes, os agricultores utilizam uma quantidade excessiva de água para irrigação, resultado da falta de informações sobre as reais necessidades hídricas das plantas. Essa prática não apenas compromete a produtividade, mas também resulta em desperdícios de água e energia. A irrigação inteligente surge como uma solução para mitigar esses desperdícios e reduzir os custos de produção. Sistemas de irrigação inteligente, como os desenvolvidos em (PERNAPATI, 2018) e (KAMIENSKI et al., 2019), utilizam sensores de umidade do ar e temperatura para monitorar a evaporação de água ao redor das plantas, além de sensores de umidade do solo que indicam a quantidade necessária de água. Nesse sistema, se os níveis de água estiverem abaixo do mínimo requerido para o desenvolvimento das plantas, o sistema monitora os níveis do reservatório e fornece água conforme necessário. Esses sensores permitem determinar exatamente quando as plantas precisam ser irrigadas, garantindo a entrega da quantidade exata de água para o seu desenvolvimento.

Os trabalhos mencionados acima ilustram como a IoT pode ser aplicada de forma eficiente na agricultura, facilitando os processos agrícolas, melhorando a qualidade e a quantidade dos produtos, além de reduzir os custos de produção.

2.3 Técnicas para Classificação de Doenças em Plantas

Um dos principais desafios da produção agrícola são as doenças e pragas que afetam as plantas, comprometendo tanto a quantidade quanto a qualidade da colheita. Muitos

estudos têm se dedicado à detecção precoce dessas ameaças para mitigar as perdas. Modelos de aprendizado de máquina e aprendizado profundo têm sido amplamente utilizados na identificação de doenças, apresentando resultados significativos.

A identificação de plantas não saudáveis é frequentemente mais perceptível ao se observar as folhas, que apresentam alterações em forma, cor e textura. Para distinguir entre folhas saudáveis e doentes, o estudo de (RAMESH et al., 2018) focou na planta do momoeiro e utilizou o método *Histogram of Oriented Gradient* (HOG) para a extração de características. A base de dados utilizada continha 160 imagens, abrangendo tanto folhas saudáveis quanto doentes. Vários classificadores foram testados, incluindo Regressão Logística, *Support Vector Machine* (SVM), *K-Nearest Neighbour* (KNN), CART, *Random Forest* e *Naïve Bayes*. O melhor resultado foi alcançado com o método *Random Forest*, que obteve uma precisão de 70%.

A detecção de doenças nas folhas de arroz foi estudada em (AHMED et al., 2019). O foco da pesquisa foi em três das doenças mais comuns que afetam as plantas de arroz: ferrugem das folhas, cretamento bacteriano e manchas castanhas. Imagens de folhas de arroz sobre fundo branco foram utilizadas como entrada. Após o pré-processamento necessário, o conjunto de dados foi treinado com diversos algoritmos de aprendizado de máquina, incluindo KNN, J48 (*Decision Tree*), *Naive Bayes* e Regressão Logística. O algoritmo J48, após validação cruzada de 10 vezes, alcançou uma precisão superior a 97% quando aplicado ao conjunto de dados de teste.

O estudo apresentado em (KUMARI; PRASAD; MOUNIKA, 2019) investigou a identificação de manchas foliares em algodão e tomate, utilizando técnicas de processamento de imagens. A segmentação das imagens foi realizada por meio do método de agrupamento *K-means*, e as características foram calculadas a partir das áreas afetadas pela doença. Foram extraídas diversas características, incluindo contraste, correlação, homogeneidade, média, desvio padrão e variância. As características obtidas dos clusters afetados foram utilizadas como entradas para o classificador de *Neural Network - NN*. Os resultados mostraram que as acurácias para a mancha bacteriana e a mancha-alvo nas folhas do algodoeiro foram de 90% e 80%, respectivamente. Para as doenças nas folhas de tomate, como septoriose e mofo, a acurácia alcançou 100%.

Durante o crescimento das plantas, especialmente nos estágios de floração e desenvolvimento dos frutos, é fundamental que recebam os diversos minerais e nutrientes necessários para um crescimento saudável. A deficiência de nutrientes pode resultar em sérios problemas de desenvolvimento, impactando diretamente o rendimento das culturas. No estudo realizado por (TRAN et al., 2019), foram analisados três nutrientes minerais Cálcio/Ca²⁺, Potássio/K⁺ e Nitrogênio (N) para avaliar o estado nutricional do tomateiro. Foram utilizadas 571 imagens de folhas e frutos de tomate em fase de crescimento. Os modelos Inception-ResNetV2/Autoencoder e média em conjunto (Ensemble) foram em-

pregados para a classificação. As taxas de precisão alcançadas foram de 87,27% e 79,09% para Inception-ResNetV2 e Autoencoder, respectivamente, enquanto o método de média em conjunto apresentou uma acurácia de 91%.

No estudo realizado por (TARIK et al., 2021), foi empregada uma rede neural convolucional (CNN) para a classificação de doenças nas folhas da batata. Foram consideradas as doenças mais comuns na região de Bangladesh, e conjunto de dados coletado pelos autores consistiu em 2.034 imagens, divididas em sete classes de doenças. As doenças identificadas nessa região incluem a pinta preta da batata, o vírus do enrolamento da folha da batata, o coração oco de batata, a crosta da batata, a podridão mole da batata, o Sutali Poka Rog e o vírus Jonita Rog. A classificação utilizando a CNN alcançou uma acurácia impressionante de 99%.

2.4 Técnicas para Classificação de Doenças no Tomate

Dentro desse contexto de doenças nas plantas, nossa atenção se volta para as abordagens que utilizam CNNs na identificação de doenças do tomateiro. Vários estudos recentes, conforme apresentado na Tabela 1, empregam essas redes convolucionais para a classificação das doenças que afetam o tomateiro.

No estudo apresentado em (BRAHIMI; KAMEL; MOUSSAOUI, 2017), os autores compararam os resultados dos modelos de aprendizado profundo, AlexNet e GoogleNet, com aqueles dos modelos Random Forest e SVM. Essa comparação validou a escolha dos modelos profundos como uma alternativa eficaz aos modelos rasos. Para a análise, foi utilizado o conjunto de dados PlantVillage com 14.828 imagens de folhas de tomateiro, classificadas em nove categorias de doenças. Os resultados indicaram que os modelos profundos alcançaram uma acurácia de 99,18%, superando significativamente os modelos rasos, que obtiveram uma acurácia de 95,47%.

O objetivo do estudo de (DURMUS; GUNES; KIRCI, 2017) foi utilizar o aprendizado profundo para detectar doenças no tomateiro em tempo real, usando um robô. Para isso, os autores utilizaram o conjunto de dados PlantVillage (HUGHES; SALATHÉ, 2015), que inclui dez classes distintas de imagens de tomate, abrangendo tanto as saudáveis quanto as afetadas por doenças. Essas classes foram empregadas para treinar e comparar duas arquiteturas: AlexNet, que alcançou uma acurácia de 95,65%, e SqueezeNet, com 94,30%.

Uma consideração importante na utilização de imagens de folhas é a complexidade do fundo, que pode comprometer a acurácia dos métodos de extração de características. Reconhecendo essa dificuldade, os autores de (SARDOGAN; TUNCER; OZEN, 2018) combinaram redes neurais convolucionais (CNN) com *Learning Vector Quantization (LVQ)*. Para essa pesquisa, foi utilizada a base PlantVillage com 500 imagens distribuídas em

quatro classes de doenças: Mancha Bacteriana, Requeima, Septória e Curvatura Amarela, além de uma classe de folhas saudáveis. O resultado obtido foi uma acurácia média de 86%.

([TM et al., 2018](#)) utilizaram o conjunto de dados PlantVillage, considerando todas as dez classes disponíveis, incluindo uma classe saudável e nove classes de doenças, totalizando 18.160 imagens. Destas, 13.360 foram empregadas para treinamento e 4.800 para testes. Para otimizar o processo de treinamento, as imagens foram redimensionadas de 256×256 para 60×60 . O classificador utilizado foi o LeNet. Durante o treinamento, foram aplicadas técnicas de aumento de dados, o otimizador Adam, e um tamanho de lote de 20, com 30 épocas de treinamento. A acurácia do classificador variou entre 94% e 95%.

([MEERADEVI et al., 2020](#)) aplicaram a arquitetura VGG16, que alcançou uma acurácia de 95% ao trabalhar com o conjunto de dados PlantVillage. No entanto, a pesquisa focou apenas em cinco doenças específicas e em folhas saudáveis. Por outro lado, a gravidade das doenças em diferentes estágios início, meio ou fim foi analisada em ([VERMA; CHUG; SINGH, 2020](#)), que empregou arquiteturas como AlexNet, SqueezeNet e InceptionV3 para avaliar a severidade da Requeima no tomate.

([SHARMA; HANS; GUPTA, 2020](#)) utilizaram o conjunto de dados PlantVillage com 20.000 imagens distribuídas em 19 classes, incluindo folhas saudáveis e doentes, com doenças como Podridão Preta, Ferrugem, Mancha Bacteriana, Pinta Preta, Requeima, Queimadura de Folhas, Mancha Alvo e Vírus do Mosaico, abrangendo diferentes culturas, como maçã, batata, tomate, uva, morango e milho. Eles treinaram e compararam o desempenho de quatro classificadores de machine learning: Regressão Logística, KNN, SVM e CNN, aplicando técnicas de processamento e segmentação de imagens para melhorar a identificação das doenças. Entre as quatro abordagens, a CNN se destacou, alcançando uma acurácia de 98,0%.

([HONG; LIN; HUANG, 2020](#)) compararam cinco arquiteturas de redes neurais profundas DenseNet-Xception, Xception, ResNet50, MobileNet e ShuffleNet, para determinar qual delas apresentaria os melhores resultados na identificação de doenças em tomates. Para essa análise, foram utilizadas 13.112 imagens de folhas de tomate provenientes do banco de dados PlantVillage. A melhor precisão de reconhecimento foi alcançada com a arquitetura DenseNet-Xception, que obteve uma acurácia de 97,10%. Em contrapartida, a menor acurácia foi registrada pela MobileNet, com um desempenho de 80,11%.

([GEHLOT; SAINI, 2020](#)) focaram na classificação de doenças nas folhas do tomateiro, utilizando diferentes modelos, incluindo AlexNet, VGG16, GoogleNet, ResNet-101 e DenseNet-121. A base de dados PlantVillage ([HUGHES; SALATHÉ, 2015](#)) foi empregada, totalizando 14.529 imagens distribuídas em 10 classes distintas. Todos os modelos demonstraram bom desempenho, mas o DenseNet-121 destacou-se ao alcançar uma acurácia de 99,97% e apresentou o menor tamanho em comparação com os demais modelos. Os modelos

ResNet-101 e VGG16 também apresentaram desempenhos similares ao do DenseNet-121.

([PUSHPA; ASHOK; V, 2021](#)) compararam três modelos de aprendizado profundo VGG16, LeNet-5 e AlexNet, em conjunto com técnicas de processamento de imagens. O conjunto de dados foi obtido do PlantVillage, contendo 7.070 imagens de folhas saudáveis e doentes de três culturas: milho, arroz e tomate. Na comparação, o VGG16 alcançou uma acurácia de 94,72%, enquanto o LeNet-5 obteve 92,4%. O AlexNet apresentou o melhor desempenho, com uma taxa de acurácia de 96,64%.

([LIJUAN; JINZHU; HUANYU, 2021](#)) realizaram uma comparação para determinar qual modelo de aprendizado de máquina e aprendizado profundo apresentaria o melhor desempenho ao trabalhar com o conjunto de dados PlantVillage. Para a análise, foram aplicadas técnicas de extração de características, focando em cor e textura. Foram implementados algoritmos clássicos de aprendizagem de máquina, como SVM, KNN e Random Forest, além de redes de classificação de aprendizado profundo, incluindo AlexNet, VGG16, ResNet34, EfficientNet-b0 e MobileNetV2. Nesse comparativo, o modelo ResNet34 se destacou, alcançando uma impressionante acurácia de 99,7% entre os classificadores testados.

Uma análise crucial refere-se ao estágio em que a doença ou o dano causado por insetos se encontra, essa análise possibilita a adoção de medidas mais específicas. O estágio das doenças no tomateiro foi investigada em ([GADADE; KIRANGE, 2021](#)), utilizando áreas de segmentação automática, nas quais as regiões infectadas das folhas são empregadas para classificar a gravidade da doença. O conjunto de dados utilizado foi o PlantVillage com 3000 imagens redimensionadas para o tamanho de 64x64. Os métodos de classificação utilizados foram linear discernment analysis(CL1), KNN(CL2), decision tree(CL3), Naïve Bayes(CL4), and Support Vector Machine(CL5). O método com melhor acurácia para a classificação em todas as análises feitas foi o SVM com 78,43%.

([DAVID et al., 2021](#)) propuseram um classificador híbrido de aprendizado profundo, combinando CNNs e *Recurrent Neural Network* (RNN) para detectar doenças em estágio inicial. O estudo utilizou o conjunto de dados PlantVillage, que contém 10 classes (nove de doenças e uma de folhas saudáveis), totalizando 2.000 imagens. O modelo desenvolvido alcançou acurácia de 98,25%, destacando-se por exigir menos poder computacional em comparação a outras abordagens.

([ISLAM et al., 2022](#)), proporam uma nova abordagem para a classificação de doenças do tomate, baseada na sumarização das saídas de várias redes neurais convolucionais paralelas, cada uma com diferentes configurações. Essa pesquisa utilizou dois conjuntos de dados: PlantVillage e Plant Factory. A implementação de camadas de ativação como Swish, LeakyReLU-Swish, ReLU-Swish, Elu-Swish e ClippedReLU-Swish, além da combinação de Batch Normalization e Instance Normalization, resultou em uma melhoria significativa no desempenho da rede, alcançando uma precisão de classificação superior a 99,0% durante o

treinamento, 97,5% na validação e 98,0% no conjunto de dados de teste.

Um novo modelo de CNN foi proposto em (SAKKARVARTHI et al., 2022). O estudo utilizou o conjunto de dados PlantVillage, focando em dez classes: nove correspondem a folhas doentes e uma a folhas saudáveis. No entanto, nem todas as imagens do conjunto foram utilizadas; os autores selecionaram apenas 300 imagens de cada classe para garantir um equilíbrio no conjunto de dados, totalizando 3.000 imagens. A divisão entre os dados de treinamento e teste foi feita na proporção de 70:30. Diferentes números de épocas também foram testados durante o treinamento. O desempenho do modelo foi comparado a outras redes pré-treinadas, como ResNet152, VGG19 e InceptionV3, e o modelo proposto demonstrou resultados superiores. O treinamento atingiu uma acurácia de 98%, enquanto a precisão no conjunto de teste foi de 88,17%.

(OMAR; JAIN; BALI, 2022) desenvolveram um modelo baseado em CNN utilizando a base de dados PlantVillage, que abrange nove classes de doenças do tomateiro, além de uma classe saudável. O conjunto de dados foi dividido na proporção de 60:40, com 8.842 imagens destinadas ao treinamento e 4.625 ao teste. A acurácia alcançada após 80 épocas de treinamento foi de 92%.

(MALUNAO et al., 2022) aplicaram o algoritmo YOLOv3 (*“You Only Look Once”*) em um conjunto de dados composto por 300 imagens, dividido na proporção de 80:20. Este estudo focou em duas doenças: a Mancha Foliar de Septoria e a Pinta Preta do tomateiro, juntamente com uma classe de folhas saudáveis. O classificador obteve uma impressionante acurácia de 98,28%.

(PRADHAN; KUMAR, 2022) avaliaram diversos modelos de CNNs pré-treinadas, incluindo DenseNet169, InceptionResNetV2, InceptionV3, VGG-16, VGG-19, DenseNet201, MobileNet, MobileNetV2 e Xception. O estudo utilizou um total de 14.532 imagens de folhas de tomateiro, pertencentes a dez classes, extraídas do banco de dados PlantVillage. O conjunto de dados foi dividido na proporção de 75:25 para treinamento e teste. Entre todos os classificadores testados, o MobileNet destacou-se, alcançando uma acurácia média de 96%.

(TURKOGLU; YANIKOGLU; HANBAY, 2022) integraram métodos de aprendizado de máquina para prever doenças em plantas. A abordagem combinou CNN para extração de características, SVM para prever as classes de saída e um método de votação majoritária. Os pesquisadores compilaram um banco de dados que abrange 15 tipos de doenças de diversas culturas observadas na Turquia, totalizando 4.447 imagens. Os resultados demonstraram um desempenho notável, com uma acurácia de 97,56% ao utilizar o modelo de votação majoritária e 96,83% com o modelo de fusão inicial.

Na pesquisa conduzida por (KHALID et al., 2023), foi proposta uma técnica que avalia três modelos de aprendizado profundo para a classificação de doenças em imagens

de folhas de tomate: ResNet-152, EfficientNet-B4 e VGG-16. O estudo utilizou o banco de dados PlantVillage, focando em apenas três doenças: Target Spot, Bacterial Spot e Septoria Spot, com um total de 5.524 imagens. Os resultados mostraram que o ResNet-152 alcançou uma precisão de 93,75%, enquanto o EfficientNet-B4 obteve uma acurácia de 97,27%. Em contraste, o VGG-16 destacou-se ao alcançar acurácia de 98%.

Com base na revisão apresentada nesta seção, nota-se que há diversos estudos abordando técnicas de identificação de doenças em plantas de tomateiro utilizando métodos de aprendizado de máquina. A maioria dos estudos utiliza o banco de dados PlantVillage devido à sua flexibilidade para diferentes estudos, ao número de culturas disponíveis e à variedade de doenças neste banco de dados. No entanto, alguns fatores importantes devem ser considerados, como a forma como essas imagens foram coletadas. Segundo o autor do banco de dados, as folhas foram coletadas da planta e fotografadas. É importante considerar que isso pode remover algumas características presentes na folha, como manchas, insetos, restos de produtos utilizados na cultura, poeira, etc. Outro fator é a qualidade das imagens. Baixa resolução pode comprometer a correta identificação de algumas doenças.

A tabela 1 resume as principais características dos trabalhos relacionados descritos nesta seção. É importante ressaltar que na maioria dos estudos sobre identificação de doenças do tomateiro, foi utilizado o mesmo banco de dados, variando apenas o número de imagens consideradas. Nesse sentido, podemos destacar que nossa metodologia de estudo está mais correlacionada aos estudos de (TARIK et al., 2021) e (AHMED et al., 2019), pois ambos também coletaram suas próprias imagens de plantas doentes e consideraram aquelas mais críticas para sua região geográfica.

2.5 Considerações Finais

Neste capítulo, foram apresentadas algumas aplicações da Agricultura de Precisão e como elas podem otimizar processos agrícolas, incluindo o gerenciamento do solo, da água, da temperatura e a identificação de doenças nas plantas. O controle de doenças de plantas permite um diagnóstico precoce, possibilitando a adoção de medidas imediatas para o controle de patógenos e, assim, reduzindo os prejuízos associados à produção. Conforme evidenciado na literatura, diversas técnicas de aprendizado de máquina, como SVM, KNN, CNN e redes pré-treinadas, têm sido empregadas na identificação de doenças em tomateiros, mostrando-se eficazes nesse contexto. No entanto, a maioria dos estudos utiliza o mesmo conjunto de dados, com as mesmas doenças. Quando outros conjuntos de dados são empregados, frequentemente o número de imagens é reduzido, o que pode comprometer o desempenho das técnicas analisadas.

Referência	Ano	Cultivo	Modelo	Dataset	Images	Classes	Acc%
(BRAHIMI; KAMEL; MOUSSAOUI, 2017)	2017	Tomate	AlexNet/GoogleNet	PlantVillage	14828	9	99.18%
(DURMUS; GUNES; KIRCI, 2017)	2017	Tomate	Random Forest/SVM	PlantVillage	14828	10	95.65%
(SARDOGAN; TUNCER; OZEN, 2018)	2018	Tomate	AlexNet/SqueezeNet	PlantVillage	500	5	86.00%
(TM et al., 2018)	2018	Tomate	CNN/LVQ	PlantVillage	18160	10	95.00%
(MEERADEVI et al., 2020)	2020	Tomate	LeNet	PlantVillage	2317	6	95.00%
(SHARMA; HANS; GUPTA, 2020)	2020	Tomate	VGG16	PlantVillage	20000	19	98.00%
(HONG; LIN; HUANG, 2020)	2020	Tomate	CNN/Logistic regression	PlantVillage	13112	19	97.10%
(GEHLOT; SAINI, 2020)	2020	Tomate	KNN/SVM/CNN	PlantVillage	14529	10	99.69%
(PUSHPA; ASHOK; V, 2021)	2021	Tomate	DenseNetXception	PlantVillage	7070	10	96.64%
(LIJUAN; JINZHU; HUANYU, 2021)	2021	Tomate	Resnet50/MobileNet	PlantVillage	18160	10	99.70%
(GADADE; KIRANGE, 2021)	2021	Tomate	SuffNet	PlantVillage	3000	9	78.43%
(DAVID et al., 2021)	2021	Tomate	ResNet101/AlexNet	PlantVillage	2000	10	98.25%
(SAKKARVARTHI et al., 2022)	2022	Tomato	DenseNet121/VGG16	PlantVillage	3000	10	88.17%
(OMAR; JAIN; BALI, 2022)	2022	Tomate	GoogleNet	PlantVillage	13467	9	92.00%
(MALUNAO et al., 2022)	2022	Tomate	AlexNet/VGG-16	PlantVillage	300	3	98.28%
(PRADHAN; KUMAR, 2022)	2022	Tomate	Lenet-5	PlantVillage	14532	10	96.00%
(TURKOGLU; YANIKOGLU; HANBAY, 2022)	2022	Outros	AlexNet/ResNet34	Outros	4.447	15	96.83%
(KHALID et al., 2023)	2023	Tomate	VGG16/EfficientNet-b0	PlantVillage	5524	3	98.00%

Tabela 1 – Estudos que utilizaram Machine Learning para classificação de doenças no tomate.

3 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, apresentamos alguns conceitos fundamentais de aprendizado de máquina, incluindo redes neurais e aprendizado profundo. Discutimos as arquiteturas CNN, VGG19 e ResNet50, abordando a importância de evitar o overfitting e os benefícios do data augmentation, técnicas de regularização, métricas de avaliação e métodos ensemble, além do algoritmo SVM. Também explicamos como as doenças em plantas se desenvolvem, destacando os agentes causadores mais relevantes no cultivo do tomate e detalhando algumas dessas doenças. Por fim, apresentamos a base de dados mais utilizada na literatura, destacando suas principais características.

3.1 Aprendizagem de Máquina

A aprendizagem de máquina, ou *Machine Learning* (ML), é um subcampo da inteligência artificial que se refere à capacidade das máquinas de imitar comportamentos humanos. Sistemas de inteligência artificial são projetados para realizar tarefas complexas de forma semelhante à maneira como os humanos resolvem problemas. O objetivo da inteligência artificial é desenvolver máquinas que demonstrem comportamentos inteligentes, equiparando-se à capacidade humana (BROWN, 2021).

O ML consiste em um conjunto de abordagens de modelagem computacional que aprendem padrões a partir de dados, possibilitando decisões automáticas sem a necessidade de programar regras específicas (MAHESH, 2019). O funcionamento do ML varia conforme a tarefa e o algoritmo empregados. A essência do processo reside na utilização dos dados para identificar semelhanças, estruturas ou diferenças que ajudem a explicar ou classificar um cenário de maneira apropriada. Uma das principais capacidades das ferramentas de ML é a capacidade de generalizar tendências e padrões a partir dos dados disponíveis.

Dada a vasta gama de ferramentas de Machine Learning disponíveis, é crucial selecionar de maneira criteriosa o método mais adequado para um problema específico. Essa escolha deve levar em conta fatores como a quantidade e o tipo de dados disponíveis, bem como a formulação do problema em questão. A função de um sistema de aprendizado de máquina pode ser descrita, segundo (ROY et al., 2022), como:

- Descritiva: técnica de análise que utiliza mineração de dados para extrair *insights* sobre eventos passados.
- Preditivo: técnica de análise que aplica metodologias estatísticas e de previsão para estimar o que é provável que ocorra no futuro.

- Prescritiva: técnica de análise que emprega algoritmos para determinar ações recomendadas, visando influenciar os resultados futuros.

Existem três subcategorias de aprendizado de máquina ([CHINNAMGARI, 2019](#)):

1. **Aprendizagem Supervisionada:** neste caso, o algoritmo é aplicado quando se conhece o resultado desejado, mas as relações entre os dados que influenciam essa saída ainda não estão claras. O objetivo é que o algoritmo de aprendizado de máquina identifique essas relações entre os diferentes elementos dos dados, permitindo assim alcançar o resultado esperado.
2. **Aprendizagem Não-Supervisionada:** nesta abordagem, os algoritmos recebem dados sem rótulos e tentam identificar padrões ou estruturas ocultas. O algoritmo agrupa os dados em categorias com atributos semelhantes, sem a necessidade de uma saída pré-definida.
3. **Aprendizagem por Reforço:** este método não se enquadra nem na aprendizagem supervisionada nem na não supervisionada. Aqui, uma definição de recompensa é fornecida inicialmente como entrada. Como o algoritmo não conta com dados rotulados para treinamento, ele não pode ser classificado como não supervisionado. Em vez disso, ele é guiado pela informação sobre a recompensa, que orienta suas ações para resolver o problema em questão.

3.2 Redes Neurais

As redes neurais são uma abordagem de aprendizado de máquina que permite que um computador aprenda a realizar tarefas por meio da análise de dados de treinamento. Normalmente, esses dados são rotulados manualmente. Por exemplo, em um sistema de reconhecimento de frutas, o sistema pode ser alimentado com milhares de imagens rotuladas de maçãs, laranjas, morangos e tomates, permitindo que ele identifique padrões visuais que se correlacionam consistentemente com esses rótulos específicos. Uma Artificial Neural Network (ANN) é um modelo matemático ou computacional inspirado na estrutura e nas funções das redes neurais biológicas ([D'ADDONA, 2014](#)). As redes neurais podem ser classificadas em diferentes categorias, conforme descrito por ([SHRESTHA; MAHMOOD, 2019](#)):

- *Feedforward Neural Network:* neste tipo de rede, os dados fluem em uma única direção, do nível de entrada até a camada de saída. Cada nó em uma camada pode estar conectado a vários nós na camada inferior, recebendo dados, e também a vários nós na camada superior, para os quais envia informações.

- *Recurrent Neural Network (RNN)*: diferentemente das redes *feedforward*, as unidades de processamento em uma RNN formam um ciclo. A saída de uma camada serve como entrada para a próxima, que geralmente é a única camada na rede. Isso cria um *loop* de *feedback*, permitindo que a rede mantenha uma memória dos estados anteriores e utilize essa informação para influenciar a saída atual. Como resultado, uma RNN pode processar sequências de entradas e gerar sequências de saídas.
- *Radial Basis Function Neural Network*: é amplamente utilizada em tarefas de classificação e previsão de séries temporais. Esta rede é composta por camadas de entrada, ocultas e de saída. A camada oculta utiliza uma função de base radial, frequentemente implementada como uma função Gaussiana, onde cada nó representa um centro de *cluster*. Durante o treinamento, a rede aprende a associar cada entrada a um desses centros. A camada de saída, por sua vez, combina as saídas da função de base radial com parâmetros de peso, permitindo que a rede realize a classificação ou faça inferências de maneira eficaz.
- *Kohonen Self Organizing Neural Network*: essa rede organiza seu modelo em relação aos dados de entrada por meio de aprendizado não supervisionado. Ela é composta por duas camadas totalmente conectadas: uma camada de entrada e uma camada de saída. A camada de saída é disposta em uma grade bidimensional. Diferentemente de outras redes, não utiliza função de ativação; em vez disso, os pesos representam os atributos (ou posições) dos nós na camada de saída. A rede calcula a distância euclidiana entre os dados de entrada e cada nó da camada de saída, com base nos pesos, permitindo que a rede se organize conforme os padrões dos dados.
- *Modular Neural Network*: a rede neural modular organiza uma rede maior em módulos menores e independentes. Cada um desses módulos é projetado para realizar tarefas específicas, permitindo uma abordagem mais flexível e escalável. Os resultados obtidos por esses módulos são então combinados para formar uma única saída, integrando as contribuições de cada parte da rede e potencializando o desempenho geral.

As redes neurais podem ser aplicadas para resolver uma variedade de problemas, incluindo classificação, agrupamento (*clustering*), redução de dimensionalidade, visão computacional, processamento de linguagem natural e regressão.

3.3 Aprendizado Profundo

O aprendizado profundo consiste em redes neurais com múltiplas camadas sequenciais, onde cada camada utiliza a saída da camada anterior como entrada. Diferente de abordagens tradicionais, o aprendizado profundo elimina a necessidade de separar a extração de características da classificação, pois o modelo extrai automaticamente as

características durante o treinamento (DURMUS; GUNES; KIRCI, 2017). Essa estrutura em camadas é capaz de processar grandes volumes de dados e determinar a relevância de cada conexão na rede. Por exemplo, em um sistema de reconhecimento de imagens, camadas iniciais podem identificar características específicas, como a cor e o tamanho da fruta, bem como a textura da superfície. Em camadas subsequentes, essas informações são combinadas para determinar a identidade da fruta com base nos padrões reconhecidos.

3.3.1 Redes Neurais Convolucionais

Uma rede neural convolucional é um classificador baseado em aprendizado profundo que recebe uma imagem como entrada e ajusta os pesos e vieses da rede com base em diversas características, permitindo que o modelo reconheça diferentes classes. Em comparação com outros classificadores, as CNNs exigem significativamente menos pré-processamento. O reconhecimento de imagens é um problema clássico para as redes neurais convolucionais, que têm demonstrado um histórico notável de alta precisão em tarefas de classificação.

3.3.2 Arquitetura CNN

As CNNs são compostas por três tipos principais de camadas: camadas convolucionais, camadas de *pooling* e camadas totalmente conectadas. As funcionalidades básicas das CNNs podem ser organizadas em quatro etapas principais (O'SHEA; NASH, 2015):

1. A imagem de entrada incluirá os valores dos *pixels* da imagem;
2. Camadas Convolucionais: Desempenham um papel fundamental no funcionamento da rede. Os parâmetros dessas camadas são compostos por *kernels* que podem ser aprendidos. Esses filtros são geralmente pequenos em termos de dimensionalidade espacial, mas se estendem por toda a profundidade da entrada. Quando os dados passam por uma camada convolucional, cada filtro é aplicado à dimensionalidade espacial da entrada, resultando em um mapa de ativação 2D. Esses mapas podem ser visualizados para análise. À medida que o filtro se desloca pela entrada, é calculado o produto escalar para cada valor presente no *kernel*. Assim, a rede aprende a identificar *kernels* que “disparam” ao detectar características específicas em determinadas posições espaciais da entrada, sendo essas respostas conhecidas como ativações. Além disso, a camada convolucional contribui para a redução da complexidade do modelo, otimizando sua saída.
3. Camadas de *pooling*: têm como objetivo reduzir gradativamente a dimensionalidade das representações, diminuindo, assim, o número de parâmetros e a complexidade computacional do modelo. Essas camadas atuam sobre cada mapa de ativação,

aplicando a função *MAX* para ajustar a dimensionalidade. Em muitas CNNs, elas são implementadas como camadas de *pooling* máximo, utilizando *kernels* de 2×2 com um passo de 2 nas dimensões espaciais da entrada. Essa abordagem reduz o mapa de ativação para 25% do seu tamanho original, mantendo a profundidade inalterada. Além do *pooling* máximo, as arquiteturas de CNN podem incluir camadas de *pooling* geral, que são compostas por neurônios agrupados capazes de realizar diversas operações, como normalização L1/L2 e *pooling* médio.

4. Camadas totalmente conectadas: essas camadas têm a função de gerar pontuações de classe a partir das ativações, que serão utilizadas para a classificação final. É recomendável o uso da função de ativação *ReLU* entre essas camadas, pois ela pode aprimorar o desempenho do modelo, acelerando o aprendizado e ajudando a mitigar o problema de *vanishing gradients*.

Por meio desses métodos, a CNN consegue transformar a camada de entrada original utilizando técnicas de convolução e redução de dimensionalidade, a fim de gerar pontuações de classe para classificação e regressão.

3.3.3 VGG-19

As VGGNets são uma série de algoritmos de redes neurais convolucionais desenvolvidos pelo Visual Geometry Group (VGG) da Universidade de Oxford, incluindo as variantes VGG-11, VGG-11-LRN, VGG-13, VGG-16 e VGG-19 (LI et al., 2020). A VGG-19 é projetada para extrair recursos de baixo e alto nível das imagens, camada por camada, permitindo uma classificação precisa. Baseada no modelo CNN, a VGG-19 foi aplicada no conjunto de dados *ImageNet* (KRIZHEVSKY; SUTSKEVER; HINTON, 2012).

Uma das principais vantagens do VGG-19 é sua simplicidade. Ele utiliza camadas convolucionais de 3×3 empilhadas para aumentar a profundidade do modelo. Para reduzir o tamanho do volume de dados, são empregadas camadas de *maxpooling*. A arquitetura do VGG-19 inclui duas camadas totalmente conectadas, cada uma com 4096 neurônios. Durante a fase de treinamento, as camadas convolucionais são utilizadas para a extração de características, enquanto as camadas de *pooling* são associadas a algumas dessas camadas convolucionais para diminuir a dimensionalidade dos recursos.

Na primeira camada convolucional, são aplicados 64 *kernels* (com filtro de 3×3) para a extração de características das imagens de entrada. As camadas totalmente conectadas são responsáveis por preparar o vetor de recursos.

3.3.4 Resnet50

A ResNet50 é uma arquitetura de rede neural convolucional desenvolvida em 2015 por pesquisadores da Microsoft Research Asia. O nome “ResNet” deriva de “rede residual”, destacando o uso de conexões residuais que ajudam a mitigar o problema de degradação frequentemente observado em redes neurais profundas. A ResNet50 tem sido amplamente aplicada em diversas tarefas de visão computacional, incluindo detecção de objetos, classificação e segmentação de imagens.

Sua arquitetura é composta por blocos residuais, que facilitam um treinamento mais eficiente e possibilitam a construção de redes mais profundas. A ResNet é caracterizada por sua flexibilidade, permitindo a construção de redes com diferentes profundidades, como ResNet18, ResNet34, ResNet50, ResNet101 e ResNet152, adaptando-se a uma variedade de problemas de aprendizado de máquina.

3.4 *Overfitting*

Overfitting ocorre quando uma rede neural se ajusta excessivamente aos dados de treinamento, resultando em um desempenho insatisfatório em dados novos, como os dados de teste (O’SHEA; NASH, 2015). Embora o modelo consiga representar bem os padrões presentes no conjunto de treinamento, ele falha em generalizar, ou seja, não consegue lidar com informações que não foram vistas durante o treinamento (SANTOS; PAPA, 2022). As causas desse fenômeno podem ser variadas e, geralmente, podem ser categorizadas em três tipos (YING, 2019):

1. **Aprendizado de ruídos no conjunto de treinamento:** isso ocorre quando o conjunto de treinamento é pequeno, contém dados pouco representativos ou apresenta muitos ruídos. Nessa situação, há uma maior probabilidade de que os ruídos sejam assimilados pelo modelo e, subsequentemente, influenciem suas previsões. Portanto, um algoritmo eficaz deve ser capaz de distinguir entre dados representativos e ruídos indesejados.
2. **Complexidade da hipótese:** o trade-off entre complexidade é um conceito fundamental em estatística e aprendizado de máquina, envolvendo a relação entre viés e variância. Refere-se ao equilíbrio entre precisão e consistência. Quando os algoritmos possuem um grande número de hipóteses (ou entradas), o modelo tende a se tornar mais preciso em média, mas com menor consistência. Isso implica que os modelos podem apresentar variações significativas em diferentes conjuntos de dados.
3. **Procedimentos de comparações múltiplas,** comuns em algoritmos de indução e em outros métodos de Inteligência Artificial (IA), envolvem a comparação de diversos itens com base nas pontuações de uma função de avaliação, visando selecionar aquele

com a pontuação mais alta. No entanto, esse processo pode resultar na escolha de itens que não apenas não melhoram, mas que podem até reduzir a precisão da classificação.

3.5 Data Augmentation

O aumento de dados é um processo de aumentar o número de amostras de treinamento em um conjunto de dados, gerando mais dados. Isso possibilita a rede aprender características mais complexas ajudando a evitar o problema de sobreajuste. O data augmentation faz com que o erro de treinamento diminua e repita esse comportamento com os dados de teste. O aumento dos dados fará com que o conjunto de dados fique mais abrangente, minimizando assim a distância entre o conjunto de treinamento e validação (SHORTEN; KHOSHGOFTAAR, 2019).

3.6 Técnica de Regularização

As redes neurais tendem a modelar os dados de treinamento de maneira tão eficaz que, em contrapartida, apresentam um desempenho insatisfatório em dados de teste, ou seja, em dados não vistos. No entanto, técnicas de regularização podem ajudar a mitigar esse problema, promovendo uma melhor generalização do modelo.

- *Dropout*: é uma técnica de regularização aplicada nas CNNs que ajuda a reduzir o overfitting. Durante o treinamento, uma porcentagem específica de neurônios em uma camada é aleatoriamente desativada em cada iteração, juntamente com suas conexões de entrada e saída. Essa abordagem aumenta a probabilidade de que diferentes neurônios sejam utilizados, o que frequentemente resulta em uma melhoria na precisão e na capacidade de generalização do modelo (SRIVASTAVA et al., 2014).
- *Early Stopping*: essa técnica permite interromper o treinamento assim que o erro de validação atinge um mínimo. O uso excessivo de épocas pode levar ao *overfitting*, enquanto o uso insuficiente pode resultar em *underfitting*. O *early stopping* monitora o desempenho do modelo a cada época e prevê quando o aprendizado se estabiliza, permitindo que o treinamento seja interrompido no momento certo (JAIN, 2020).

3.7 Métricas de Avaliação

A eficácia dos algoritmos de aprendizado de máquina é frequentemente avaliada por meio de um conjunto de métricas de desempenho (KANSTRÉN, 2020). As principais métricas utilizadas para avaliar o desempenho de um modelo na tarefa de classificação incluem (IGUAL et al., 2017):

- **Acurácia:** é definida como a proporção de previsões corretas em relação aos dados de teste. Essa métrica pode ser calculada de forma simples, dividindo o número de previsões corretas pelo total de previsões realizadas. Sua fórmula é a seguinte:

$$Acurácia (\%) = \frac{TP + TN}{TP + FP + TN + FN} \times 100 \quad (3.1)$$

onde:

TP (True Positives) representa o número de verdadeiros positivos,

TN (True Negatives) representa o número de verdadeiros negativos,

FP (False Positives) refere-se ao número de falsos positivos, e

FN (False Negatives) refere-se ao número de falsos negativos.

- **Precisão:** é a proporção de exemplos relevantes (verdadeiros positivos) em relação a todos os exemplos que foram classificados como pertencentes a uma determinada classe. Sua fórmula é a seguinte:

$$Precisão (\%) = \frac{TP}{TP + FP} \times 100 \quad (3.2)$$

- **Revocação:** é a proporção de exemplos corretamente identificados como pertencentes a uma classe em relação a todos os exemplos que realmente pertencem a essa classe. Sua fórmula é expressa da seguinte maneira:

$$Recall (\%) = \frac{TP}{TP + FN} \times 100 \quad (3.3)$$

- **F1 score:** é uma métrica utilizada para avaliar a performance de modelos de classificação, especialmente em contextos com desbalanceamento entre as classes. Ela combina duas medidas fundamentais: Precisão (P): a proporção de previsões verdadeiras positivas em relação ao total de previsões positivas (verdadeiras positivas + falsas positivas). Recall (R): a proporção de previsões verdadeiras positivas em relação ao total de positivos reais (verdadeiras positivas + falsas negativas).

Essa métrica é particularmente útil para garantir um equilíbrio entre precisão e recall, oferecendo uma visão mais completa da eficácia do modelo.

$$F1 (\%) = \frac{2 \cdot P \cdot R}{P + R} \times 100 \quad (3.4)$$

- **Matriz de Confusão:** é uma ferramenta eficaz para avaliar o desempenho de modelos de classificação, especialmente quando as saídas podem pertencer a duas ou mais classes. Essa matriz é apresentada na forma de uma tabela bidimensional conforme a Tabela 2, com as dimensões “Real” e “Previsto”. Cada dimensão contém os seguintes elementos: “Verdadeiros Positivos (TP)”, “Verdadeiros Negativos (TN)”, “Falsos Positivos (FP)” e “Falsos Negativos (FN)”. A informação pode ser organizada de maneira clara em uma matriz de confusão, conforme ilustrado a seguir:

	Positivo	Negativo
Positivo	TP	FP
Negativo Previsto	FN	TN

Tabela 2 – Matriz de confusão.

3.8 Support Vector Machine - SVM

O algoritmo SVM foi Inicialmente projetado para resolver problemas de classificação binária (VAPNIK, 1995). Com o tempo, ele foi estendido e adaptado para lidar também com desafios de classificação multiclasse (CRAMMER et al., 2002). Seu objetivo é encontrar o hiperplano ótimo $f(w, x) = w \cdot x + b$ para separar duas classes em um determinado conjunto de dados, com características $x \in \mathbb{R}^m$. O SVM aprende os parâmetros w resolvendo o problema de otimização definido pela Eq. 3.5,

$$\min \frac{1}{p} \cdot \|w\|_1 + C \cdot \sum_{i=1}^p \max(0, 1 - y'_i \cdot (w^T x_i + b)) \quad (3.5)$$

onde, $\|w\|_1$ é a norma Manhattan (também conhecida como norma L1), C é o parâmetro de penalidade (que pode ser um valor arbitrário ou selecionado por meio de ajuste de hiperparâmetros), y'_i é o rótulo real, e $w^T x_i + b$ é a função preditora. A equação 3.5 é conhecida como L1-SVM, que utiliza a função de perda hinge padrão. A versão diferenciável, chamada de L2-SVM, definida pela equação 3.6, fornece resultados mais estáveis.

$$\min \frac{1}{p} \cdot \|w\|_2^2 + C \cdot \sum_{i=1}^p \max(0, 1 - y'_i \cdot (w^T x_i + b))^2 \quad (3.6)$$

onde, $\|w\|_2^2$ é a norma Euclidiana (também conhecida como norma L2), com a perda hinge quadrática. A L2-SVM tende a fornecer resultados mais estáveis devido à sua diferenciabilidade.

3.9 Ensemble Voting

Os métodos ensemble baseiam-se na premissa de que a combinação dos resultados de múltiplos modelos de aprendizado de máquina pode aprimorar a acurácia da identificação (DONG; CAO; MA, 2020). Existem diversas abordagens de métodos ensemble, incluindo voting, bagging, boosting e stacking. Neste estudo, foi adotado o método de voting (BURKA et al., 2022). A votação pode ser realizada de duas formas em problemas de classificação: Hard voting, em que cada modelo emite seu voto para uma classe, e a classe com mais votos é escolhida, e Soft voting, que leva em consideração as probabilidades associadas a

cada classe, selecionando aquela com a maior probabilidade, mesmo que o modelo não esteja totalmente seguro sobre a classificação.

Cada classificador, i , pega uma entrada e gera um vetor com as probabilidades das classes, $\mathbf{p}_i = [p_{i1}, p_{i2}, \dots, p_{ik}]$, onde $\sum_k p_{ik} = 1$. Cada CNN tem sua própria arquitetura, e as probabilidades que elas geram são combinadas por meio de votação. A votação Hard é baseada no cálculo da categoria prevista para cada classificador,

$$y_i = \arg \max(\{p_{i1}, p_{i2}, \dots, p_{ik}\})$$

onde a categoria final é determinada através do modo de todos eles:

$$y = \text{mode}(\{y_1, y_2, \dots, y_n\}).$$

A votação suave pode ser feita como uma soma ponderada das probabilidades dadas por cada classificador. A probabilidade de pertencer à classe k prevista pelo conjunto (CRUZ et al., 2021) é calculada usando a seguinte equação,

$$P_k = \sum_{i=1}^n w_i \cdot p_{ik}$$

onde n é o número de CNNs consideradas no conjunto. Os pesos w_i são atribuídos com base no desempenho de treinamento das redes, onde os pesos mais altos correspondem aos menores erros. A categoria selecionada, y , é aquela com a maior probabilidade:

$$y = \arg \max(\{P_1, P_2, \dots, P_k\})$$

A Figura 3 (a) mostra como o método Hard funciona, usando três modelos capazes de prever duas classes possíveis rotuladas 0 e 1. A classe 1 obteve mais votos porque foi prevista por dois dos três modelos. A votação Soft mostrada na Figura 3 (b) calcula a média das probabilidades de classe dos modelos de classificação selecionando aquele com a maior probabilidade média.




Figura 3 – Métodos de Votação.

3.10 Doenças de Plantas

Uma doença de planta é definida como qualquer anormalidade que, causada por agentes bióticos ou abióticos, altera continuamente o metabolismo das plantas ao longo do ciclo da cultura. Essas anormalidades podem ocorrer em qualquer fase de crescimento, comprometendo o desenvolvimento e o crescimento das plantas (LOPES; AVILA, 2005). Os danos provocados por patógenos podem levar à destruição de tecidos ou até à morte da planta, impactando negativamente a produtividade e a qualidade do produto. Além disso, as doenças das plantas são fortemente influenciadas pelas condições ambientais; um hospedeiro suscetível não será infectado por um patógeno virulento se o ambiente não for propício para o desenvolvimento da doença (VELÁSQUEZ, 2018). Quando fatores ambientais se tornam desfavoráveis, o crescimento da planta é alterado, resultando em características anormais em comparação às plantas que crescem em condições favoráveis. A expressão “doenças de plantas” pode ser aplicada a qualquer alteração significativa no desenvolvimento fisiológico ou na estrutura da planta, desde que seja prolongada o suficiente para que as manifestações externas se tornem evidentes (RAVA; SARTORATO, 1994).

A frequência e intensidade das doenças em tomateiros são influenciadas por diversos fatores, conforme ilustrado na Figura 4 (LOPES; AVILA, 2005).




Figura 4 – Fatores que determinam a intensidade da doença no tomateiro.

Atualmente, mais de 200 pragas e doenças foram identificadas em tomateiros, resultando em perdas significativas na produção, tanto direta quanto indiretamente (VK SINGH AK, 2017). Essas doenças podem ser causadas por fungos, bactérias, nematoides,

vírus e distúrbios fisiológicos. De acordo com (LOPES; AVILA, 2005), as doenças mais relevantes que afetam o tomateiro estão listadas na Tabela 3. Embora muitas dessas doenças ocorram tanto em campo aberto quanto em ambientes protegidos, a singularidade das condições ambientais em estufas faz com que certas doenças sejam mais prevalentes nesses locais, enquanto outras são mais comuns ao ar livre. Neste estudo, abordaremos especificamente as doenças causadas por fungos, bactérias e vírus em ambientes de estufa.

Doenças do Tomateiro								
Doenças Fúngicas	Doenças Bacterianas	Doenças Viróticas	Nematoides	Doenças Relacionadas ao clima	Deficiências Nutricionais	Distúrbios Genéticos ou casos pouco conhecidos	Doenças causadas por insetos ou ácaros	Doenças pós colheita
Tombamento de mudas	Murchadeira	Topo-amarelo	Nematóide-de-galhas	Enrolamento fisiológico dos folíolos	Deficiência de fósforo	Planta cega	Pulgões	Podridão-mole
Pinta preta	Cancro bacteriano	Mosaico-do fumo		Baixo índice de pegamento de fruto	Deficiência de nitrogênio	Quimeras	Mosca Branca	Podridão-de-rizopus
Septoriose	Mancha bacteriana	Vira-cabeça		Rachaduras de crescimento	Deficiência de magnésio	Deformação de frutos	Percevejos	Podridão-de-azedo
Mancha de estenfilio	Pinta bacteriana	Risca-do-tomateiro		Rachaduras de crescimento	Deficiência de boro	Cicatrizes em zíper	Mosca minadora	Podridão-de fusário
Mancha de cladospório	Talo-oco	Mosaico-amarelo		Rachaduras cuticulares	Deficiência de cálcio	Mancha-dourada	Ácaro-do-bronzeamento	Atracnose
Oídio	Mancha da medula	Mosaico-dourado-do-tomateiro		Ombro-amarelo		-do-fruto		Podridão-de rizotonia
Bolor cinzento	Syngae			Queima-do-sol				
Mancha Alvo	Necrose			Frutos ociosos				
Murcha-do-esclerócio				Frutos amarelos				
Podridão de esclerotina				Ferimento por granizo				
Murcha-de-fusário				Murcha-d'água				
Rizoctoniose								
Podridão olho-de-veado								
Murcha-de-verticílio								

Tabela 3 – Principais doenças do tomateiro.

3.10.1 Oídio

Os fungos são responsáveis por uma significativa quantidade de doenças nas plantas, causando grandes prejuízos na tomaticultura. Os fungos de solo, em particular, são os mais difíceis de controlar, pois muitas vezes não apresentam sintomas visíveis, exigindo a adoção de medidas integradas de manejo. Os fungicidas são amplamente recomendados para combater doenças fúngicas, que podem representar cerca de 15% do custo de produção (LOPES; AVILA, 2005).

O oídio é uma das doenças mais importantes nos cultivos em estufas, onde as temperaturas geralmente são mais elevadas. A ausência de chuvas ou irrigação por aspersão, uma vez que a irrigação em estufas é frequentemente realizada por gotejamento, também contribui para o aparecimento dessa doença. Embora o oídio seja mais comum em ambientes protegidos, ele também pode ser encontrado em plantações a céu aberto. Esta doença é causada por duas espécies de fungos: *Oidium lycopersici* (também conhecido como *Erysiphe cichoracearum*) e *Oidiopsis sicula* (ou *Leveillula taurica*). Ambas as espécies estão amplamente distribuídas em todas as regiões do país, sendo a segunda conhecida por ter um elevado número de hospedeiras. A disseminação desses fungos ocorre principalmente

pela ação do vento, e sua principal característica é a presença abundante de um pó branco e fino na superfície superior das folhas (LOPES; AVILA, 2005).

3.10.2 Mancha Bacteriana

As bactérias são organismos microscópicos e unicelulares que se multiplicam rapidamente por meio de divisão celular, absorvendo nutrientes do ambiente. Sua disseminação em novos locais pode ocorrer por meio de sementes ou pelo transplante de mudas contaminadas (DAMICONE; BRANDENBERGER, 2017). Uma vez estabelecidas, as bactérias se espalham por meio de sistemas de irrigação, chuvas, névoas, equipamentos, insetos e pessoas que trabalham nas proximidades das plantas. Além disso, elas podem persistir em ervas daninhas, plantas voluntárias e restos de culturas que geralmente não são removidos da propriedade, tanto na lavoura de tomate quanto em seus arredores. As bactérias penetram nas plantas por meio de aberturas naturais ou feridas.

A Mancha Bacteriana é uma doença comum em lavouras de tomate e pimentão, favorecida por temperaturas entre 20°C e 30°C. A combinação de chuvas, ventos fortes e terrenos arenosos agrava a severidade da doença nessas regiões. A Mancha Bacteriana pode afetar todos os órgãos aéreos da planta, reduzindo sua produtividade devido à destruição do tecido foliar e à queda de flores e frutos em formação. Inicialmente, a doença se manifesta nas folhas mais velhas como manchas marrons de formato irregular, frequentemente com o centro perfurado, concentradas nas bordas.

Além disso, a doença compromete a qualidade do produto, tanto para o consumo *in natura*, devido às manchas nos frutos que limitam sua comercialização, quanto para o processamento industrial, uma vez que a exposição direta à insolação, decorrente da desfolha, reduz o teor de açúcar nos frutos, resultando em desvalorização do produto (LOPES; AVILA, 2005).

3.10.3 Mosaico-dourado-do-tomateiro

Os vírus são partículas menores do que uma única célula, visíveis apenas por microscopia eletrônica. Nas plantas, a maioria dos vírus é disseminada por insetos, embora alguns possam ser transmitidos mecanicamente quando feridas nas plantas entram em contato com seiva infectada. Na natureza, a dispersão de patógenos é altamente especializada, sendo predominantemente realizada por insetos vetores, como pulgões, moscas-brancas, cigarrinhas e tripses (LOPES; AVILA, 2005). Uma vez dentro da planta, os vírus se multiplicam e se espalham por todo o organismo vegetal.

O mosaico-dourado-do-tomateiro é uma doença grave causada por *geminavírus*, caracterizada por sua alta contagiosidade e considerada a virose mais severa que afeta a cultura do tomate, tanto em estufas quanto em campo aberto. Sua disseminação ocorre

principalmente através da mosca-branca, sendo o gênero mais comum o (*Bemisia tabaci* biótipo *B* ou *B. argentifolii*), com mais de dez espécies de *geminivírus* identificadas no Brasil.

Os sintomas podem aparecer em qualquer estágio de crescimento da planta e incluem manchas regulares, mosaicos, rugosidade e deformações foliares. Outro sintoma observável é o amadurecimento desigual dos frutos, que, embora associado aos vírus, é na verdade provocado pelas toxinas injetadas pela mosca-branca (LOPES; AVILA, 2005).

3.10.4 Minadora

As moscas-minadoras pertencem à ordem *Diptera*, família *Agromyzidae* e gênero *Liriomyza*. São conhecidas por diversas denominações, como bicho-minador, mineiro e riscador de folha. O gênero *Liriomyza* abriga 376 espécies, entre as quais se destacam *Liriomyza huidobrensis* (Blanchard), *L. trifolii* (Burgess), todas nativas do Novo Mundo e amplamente distribuídas nas Américas do Norte e do Sul (LOPES; AVILA, 2005).

Esses insetos são comuns no Brasil, onde ocorrem naturalmente em todas as regiões do país. Eles atacam uma vasta gama de plantas, abrangendo cerca de 14 famílias, incluindo ornamentais, feijões e oleráceas, com destaque para batata, tomate, alface, melancia e melão. Essa diversidade de hospedeiros aumenta a importância das moscas-minadoras, gerando preocupações entre os produtores em várias regiões do país (LIMA, 2019). A maior incidência desses insetos ocorre durante o período vegetativo, quando se alimentam do mesófilo foliar, formando minas nas folhas e reduzindo a área fotossintética e a capacidade produtiva da planta (PRATISSOLI et al., 2015).

3.11 Bases de Dados PlantVillage

Um dos grandes desafios da Inteligência Artificial é a qualidade e a quantidade dos dados disponíveis. Na agricultura, essa questão se torna ainda mais evidente, pois a coleta automática e em grande escala de dados é limitada, e os avanços em Internet das Coisas nessa área ainda estão em fase inicial. Além disso, muitas propriedades rurais carecem de acesso à internet devido à sua localização, o que complica ainda mais esse processo.

A base de dados PlantVillage (HUGHES; SALATHÉ, 2015) é amplamente utilizada para estudos relacionados a doenças de diversas plantas, contendo 54.303 imagens de folhas saudáveis e não saudáveis, distribuídas em 38 categorias por espécie e doença. As imagens, com tamanho de 256×256 pixels, incluem várias espécies, como maçã, cereja, milho, batata, uva, laranja, pêssego, pepino e tomate. Essas fotos foram capturadas em laboratório, a partir de folhas coletadas diretamente das plantas em cultivo, em um ambiente controlado.

Para o tomate, a base conta com 18.160 imagens, conforme detalhado na Tabela 4.

Essa tabela apresenta a quantidade e a divisão das 10 classes, sendo uma classe saudável e nove classes associadas a diferentes doenças: mancha bacteriana, praga precoce, requeima, mofo da folha, mancha de septória, ácaro de aranha, mancha alvo, vírus do mosaico e vírus da folha amarela.

Doença	Imagens
Saudáveis	1591
Mancha Bacteriana	2127
Ferrugem Precoce	1000
Requeima	1909
Mofo da Folha	952
Mancha de Septória	1771
Ácaro de Aranha	1676
Mancha Alvo	1404
Vírus do Mosaico	373
Vírus da Folha Amarela	5357
Total	18,160

Tabela 4 – Número de imagens por classe PlantVillage para doenças do Tomate.

3.12 Considerações Finais

Neste capítulo, foram discutidos os fundamentos do aprendizado de máquina, suas principais aplicações, categorias e métodos, incluindo redes neurais, aprendizado profundo, redes neurais convolucionais e redes pré-treinadas. Além disso, foram apresentados os métodos ensemble, como *Hard* e *Soft voting*, e sua capacidade de aprimorar a acurácia na identificação. Um desafio importante abordado foi o *overfitting*, que questiona se uma rede está realmente aprendendo, junto com soluções para mitigar esse problema, como *data augmentation* e *dropout*. O capítulo também explorou os danos e fatores que podem causar doenças em plantas, com ênfase nas patologias que afetam o tomate. Foram discutidas algumas das doenças mais relevantes dessa cultura. Por fim, foi apresentada a base de dados mais utilizada na literatura, destacando a quantidade e os tipos de doenças documentadas.

4 MODELO DE SISTEMA

Este capítulo detalha o processo de aquisição das imagens de folhas de tomate, tanto saudáveis quanto afetadas por doenças e pragas, para a formação do conjunto de dados. Serão discutidos os métodos utilizados para a coleta, a resolução das imagens para adequação às redes neurais convolucionais, as classes resultantes e a quantidade total de imagens obtidas. Além disso, serão apresentados os três modelos utilizados, incluindo suas arquiteturas, modificações e parâmetros empregados, com o objetivo de otimizar o desempenho do classificador.

4.1 Conjunto de Dados

A disponibilidade de dados é essencial para o desenvolvimento de técnicas de identificação de doenças por meio de algoritmos de aprendizado de máquina. O desempenho dos modelos de aprendizado profundo é fortemente influenciado pela quantidade de dados disponíveis. A escassez de imagens adequadas pode levar ao fenômeno de *overfitting*, resultando em um desempenho insatisfatório durante a validação. Embora a literatura não forneça uma definição precisa sobre o número ideal de imagens necessárias para classificação (BARBEDO, 2018), é amplamente reconhecido que uma maior quantidade de imagens contribui para uma melhor precisão do classificador.

No contexto agrícola, a disponibilidade de imagens pode ser limitada, variando conforme o tipo de cultura e as condições de cultivo. Muitas vezes, não existem conjuntos de dados suficientes e atualizados para embasar estudos e pesquisas. Por isso, a coleta e a organização de um conjunto de dados específico com imagens de doenças do tomateiro foram condições fundamentais para este trabalho, que se concentra no cultivo de tomate em estufas.

4.1.1 Conjunto de dados de imagens de folhas do tomate (Tomato Leaf Image Dataset (TLID))

O TLID foi desenvolvido por meio de diversas visitas a produtores na região norte do Paraná, especificamente na cidade de Faxinal, entre dezembro de 2020 e junho de 2021. Foram visitadas três propriedades distintas, cada uma com várias estufas, permitindo a identificação de diferentes doenças em diversos estágios de desenvolvimento. As visitas foram realizadas em períodos alternados, e as plantas foram fotografadas com um smartphone na resolução de 4608×2592 .

Foram capturadas imagens dos ramos do tomateiro, tanto com quanto sem lesões, conforme ilustrado na Figura 5. Posteriormente, as imagens foram editadas utilizando o Software Paint3D (Corporation Microsoft, 2019), a fim de reduzir sua resolução e remover informações de fundo. Essa edição teve como objetivo eliminar o aprendizado de características irrelevantes, concentrando-se apenas nas características específicas das doenças. O fundo das imagens foi definido como cinza, uma cor neutra escolhida durante o processo de edição.

As folhas foram recortadas individualmente de cada ramo, resultando em imagens com o tamanho de 256×256 pixels. Todas as imagens foram originalmente salvas no formato RGB, com 3 canais. Um pequeno script foi configurado para atribuir um valor numérico como rótulo a cada imagem, baseado em seu prefixo. Assim, imagens com prefixo zero (0) correspondiam à classe saudável, prefixo um (1) referia-se à mosca-minadora, e assim por diante.



Figura 5 – Ramos do tomateiro infectado com doenças.

O conjunto de dados criado a partir das imagens pré-processadas inclui 7 classes distintas, compostas por seis tipos de doenças e uma classe representando a folha saudável. As doenças e pragas identificadas foram: Oídio, Minadora, Mancha Bacteriana, Mosca Branca, além de combinações dessas condições, como Oídio e Minadora, e Mancha Bacteriana e Minadora. No total, a edição resultou em 15.256 imagens, distribuídas conforme apresentado na Tabela 5.

As folhas saudáveis coletadas estão ilustradas na Figura 6 e foram fotografadas em diferentes horários do dia. Essa abordagem foi intencional, permitindo capturar as folhas sob diversas condições de incidência de luz. Na mesma figura, é possível observar sombras projetadas sobre as imagens. Outro problema significativo é a Mosca Minadora, diferentes ataques desse inseto é mostrado na Figura 7.

A propriedade fotografada apresenta um histórico prolongado de problemas com a Mancha Bacteriana mostrada na Figura 8, devido à prática de não remoção dos restos de

Classe ID	Classe	Imagens
1	Saudável	2,688
2	Mosca Minadora	2,255
3	Mancha Bacteriana	2,395
4	Oídio	2,181
5	Oídio e Mosca Minadora	2,362
6	Mancha Bacteriana e Mosca Minadora	2,503
7	Mosca Branca	872
	Total	15,256

Tabela 5 – Número de imagens por Classe.

cultura, o que permite a sobrevivência das bactérias e a reinfecção das novas mudas.

As múltiplas visitas às propriedades possibilitaram a documentação das doenças em diferentes estágios de desenvolvimento, com os estágios da doença Oídio sendo apresentados na Figura 9. O mosaico-dourado-do-tomateiro, causado por geminivírus, é considerado a virose mais grave na cultura do tomate atualmente. Esses geminivírus são transmitidos pela Mosca Branca (*Bemisia tabaci*, biótipo B ou *B. argentifolii*) (LOPES; AVILA, 2005) e são responsáveis pela redução da qualidade e da quantidade dos frutos. O inseto Mosca Branca é mostrada na Figura 12.

A ocorrência de múltiplas doenças na cultura do tomate é bastante comum; em casos raros, uma planta pode ser afetada por até cinco doenças simultaneamente (LOPES; AVILA, 2005). A Figura 10 exemplifica a coocorrência de duas doenças: oídio e mosca minadora, e a Figura 11 a ocorrência de mancha bacteriana e mosca minadora.



Figura 6 – Folhas Saudáveis com influência de sombras na imagem.

4.1.2 Conjunto de dados de Patches de folhas do tomate (Patch-based Tomato Leaf Image Dataset (PTLID))

Na construção do PTLID, optamos por focar exclusivamente nas áreas infectadas pela doença. Para isso, subdividimos as folhas do Dataset TLID em 64 imagens com dimensões de 32×32 pixels. Após essa divisão, as partes contendo as doenças foram separadas e anotadas uma a uma manualmente, desconsiderando as demais partes da folha.



Figura 7 – Diferentes tipos de ataques da Mosca Minadora.



Figura 8 – Evolução da doença Mancha Bacteriana.



Figura 9 – Evolução da doença Oídio.



Figura 10 – Combinação de duas doenças Oídio e Minadora.

A Figura 13(a) apresenta uma folha com tamanho 256×256 pixels, enquanto a Figura 13(b) exibe a imagem dividida para extração das partes afetadas por doenças ou pragas.

A Figura 14 apresenta o resultado da extração dos patches das imagens de folhas saudáveis do conjunto TLID. A Figura 15 exibe patches com ataques de Mosca Minadora, enquanto a Figura 16 mostra diferentes estágios de contaminação pela Mancha Bacteriana. A Figura 17 ilustra o contágio pela doença Oídio. Já a Figura 18 apresenta patches com a combinação das doenças Oídio e Mosca Minadora, e a Figura 19 mostra a combinação de





Figura 11 – Combinação de duas doenças Mancha Bacteriana e Minadora.



Figura 12 – Mosca Branca, inseto transmissor do Mosaico-dourado-do-tomateiro.



(a) Folha 256×256.

(b) Patches 32×32.

Figura 13 – Diferentes tamanhos de imagens usadas no método proposto.

Mancha Bacteriana e Mosca Minadora. Por fim, a Figura 20 exibe patches que contêm o inseto Mosca Branca e a Figura 21 os patches do fundo da imagem.




Figura 14 – Patches Saudáveis.

A **Tabela 6** apresenta a quantidade de imagens por classe resultante da divisão das imagens em patches. Além das classes presentes no TLID, também foram incluídas imagens de fundo neste PTLID. No total, contabilizamos 227.218 imagens, distribuídas




Figura 15 – Patches Minadora.




Figura 16 – Patches Mancha Bacteriana.




Figura 17 – Patches Oídio.




Figura 18 – Patches Oídio e Minadora.




Figura 19 – Patches Mancha Bacteriana e Minadora.




Figura 20 – Patches Mosca Branca.

entre oito classes diferentes.




Figura 21 – Patches Fundo da imagem.

Class ID	Class	Images
1	Saudável	48,676
2	Mosca Minadora	11,099
3	Mancha Bacteriana	55,213
4	Oídio	60,628
5	Oído e Mosca Minadora	10,653
6	Mancha Bacteriana e Mosca Minadora	15,435
7	Mosca Branca	1,060
8	Fundo	24,454
	Total	227,218

Tabela 6 – Número de patches por classe.

4.2 Método Proposto

A arquitetura proposta neste estudo é composta por três etapas principais, que foram aplicadas de forma uniforme a ambos os conjuntos de imagens: construção do conjunto de dados, fluxo do sistema e votação do conjunto. O diagrama de blocos detalhado do método proposto pode ser visualizado na Figura 22.

Na etapa de construção do conjunto de dados, utilizamos imagens provenientes dos conjuntos de dados descritos na Seção 4.1. Dispomos de dois conjuntos de dados com tamanhos de imagem distintos: um com imagens de 256×256 pixels e outro com patches de 32×32 pixels. As imagens de 256×256 foram redimensionadas para 224×224 pixels na entrada da rede, enquanto as imagens de 32×32 permaneceram inalteradas. Ambas as categorias de imagens são codificadas em RGB e armazenadas no formato JPG. No passo Fluxo do Sistema utilizamos três CNNs uma customizada e duas pré treinadas a VGG19 e a Resnet50 e testamos duas saídas de redes o Softmax e SVM. Na etapa de Votação em Conjunto, adotamos dois tipos de abordagem: Hard Voting e Soft Voting. ’

4.2.1 CNN modelo customizado

A CNN é um método amplamente utilizado na classificação de imagens, graças à flexibilidade que sua arquitetura oferece, permitindo variações no número de camadas convolucionais, tipos e tamanhos de filtros, além de procedimentos de *pooling* e *dropout*. Essa adaptabilidade contribui significativamente para a melhoria do desempenho da rede.




Figura 22 – Diagrama de blocos do método proposto.

Neste estudo, desenvolvemos uma nova arquitetura de CNN e ajustamos hiperparâmetros, incluindo o número de camadas convolucionais, camadas totalmente conectadas, quantidade de filtros e métodos de pooling. A seleção dos hiperparâmetros foi realizada manualmente por meio de simulações, resultando no modelo que apresentou os melhores resultados.

A arquitetura da CNN proposta está ilustrada na Figura 23. Ela consiste em três blocos convolucionais, cada um composto por duas camadas convolucionais seguidas por uma camada de *pooling*. Ao final do modelo, adicionamos duas camadas totalmente conectadas: uma com 512 neurônios e outra com sete neurônios, representando as classes a serem identificadas. Utilizamos *dropout* de 0,5 entre as camadas totalmente conectadas para mitigar o *overfitting*. A estrutura de todos os modelos permaneceu a mesma para




Figura 23 – A arquitetura do modelo CNN customizado.

os dois conjuntos de dados utilizados, variando apenas o tamanho da imagem de entrada conforme o respectivo conjunto de dados. Outros parâmetros utilizados para ajustar os modelos estão listados a seguir:

- Divisão dos Dados: o conjunto de dados foi dividido em duas partes: uma destinada ao treinamento do classificador e outra para validação com dados não vistos. A proporção estabelecida foi de 80/20, ou seja, 80% dos dados foram utilizados para treinamento/teste e 20% para validação. Para o treinamento a proporção foi de 70/30, ou seja, 70% para treino e 30% para teste.
- Número de Épocas: o número de épocas refere-se à quantidade de vezes que todo o conjunto de dados de treinamento é apresentado à rede durante o processo de treinamento. O modelo foi treinado com diferentes quantidades de épocas, variando de 50 a 100, e foi aplicado o método de *Early Stopping* para interromper o treinamento quando não houve mais aprendizado.
- Otimizadores/Taxa de Aprendizagem: diversos otimizadores foram testados, incluindo *Stochastic Gradient Descent* (SGD) , *Root Mean Square Propagation* (RMSPROP), *Adaptive Gradient Algorithm* (Adagrad) e *Adaptive Moment Estimation* (Adam). O otimizador que apresentou o melhor desempenho foi o Adam.
- Taxa de Aprendizagem: a taxa de aprendizado é um parâmetro crucial durante a atualização dos pesos de um modelo, ela define o tamanho dos passos que o modelo dá ao minimizar a função de erro ou de perda. Um dos desafios em nossos experimentos foi a escolha da taxa de aprendizado ideal. Para encontrar o melhor valor, testamos diferentes taxas de aprendizado: 0,01, 0,001 e 0,0001. Entre elas, a taxa de 0,0001 mostrou-se a mais adequada, proporcionando os melhores resultados em todos os testes realizados para os modelos pré treinados. Para a CNN customizada o melhor valor encontrado foi de 0,001.
- Tamanho do Lote: o conjunto total de dados de treinamento foi dividido em pequenos subconjuntos, chamados mini lotes. O tamanho de cada mini lote foi definido como 64, embora também tenham sido testados tamanhos de 16, 32, 128 e 256.
- Função de Ativação: as funções de ativação são utilizadas em redes neurais para introduzir não linearidade nos modelos, permitindo que a rede aprenda padrões complexos. Diferentes funções de ativação foram testadas, incluindo ReLU (Rectified Linear Unit), Sigmoid e Leaky ReLU. Entre elas, a ReLU apresentou os melhores resultados.
- Data Augmentation: A técnica de aumento de dados foi aplicada apenas ao método que considera a análise da folha de forma global, com imagens de tamanho 256×256 .

Para os patches, essa abordagem não foi necessária, uma vez que o conjunto de dados já possuía uma quantidade suficiente de imagens.

- Função de ativação na saída da rede: os experimentos foram realizados utilizando duas abordagens: a função de ativação Softmax, comumente empregada na camada de saída de redes neurais para problemas de classificação multiclasse, e o SVM (Support Vector Machine), que, embora não seja uma função de ativação, é um modelo de classificação que pode ser usado como alternativa para tarefas de classificação. Nesse experimento optamos por utilizá-lo de forma linear.
- *Dropout*: foi utilizado *dropout* de 0.5 entre as camadas densas.

4.2.2 Modelo VGG19

Optamos por utilizar a arquitetura pré-treinada VGG19 para analisar seu comportamento com o novo conjunto de dados e realizar uma comparação de desempenho com os outros dois modelos. Essas redes pré-treinadas já demonstraram sucesso em diversas aplicações com diferentes conjuntos de dados. A arquitetura da VGG19 é composta por 19 camadas convolucionais (SIMONYAN; ZISSERMAN, 2014), organizadas em cinco blocos de convolução seguidos por camadas de *pooling*. Na camada de saída, utilizam-se camadas densas.

A Figura 24 ilustra a arquitetura proposta, que recebe imagens de entrada com tamanho fixo de $224 \times 224 \times 3$, conforme o padrão do modelo. Em cada camada de *pooling*, a dimensão é reduzida, enquanto o número de filtros é dobrado em relação às camadas convolucionais anteriores. Incluímos duas camadas densas: uma com 512 neurônios e outra com 7, representando as classes a serem identificadas. Testamos este modelo com duas funções de ativação de saída de rede *Softmax* e SVM para determinar o resultado da classe mais provável.

Para evitar *overfitting*, aplicamos um *Dropout* de 0,5 entre as duas camadas densas. Além disso, empregamos *data augmentation* para aumentar o conjunto de dados. A taxa de aprendizado foi ajustada para 0,0001, uma vez que a configuração padrão do otimizador Adam (0,001) não apresentou um desempenho satisfatório nesta arquitetura.

4.2.3 Modelo Resnet50

Enquanto redes neurais convencionais aprendem características de baixo e alto nível durante o treinamento, a ResNet (Rede Neural Residual) (HE et al., 2016) se concentra em aprender resíduos. Essa abordagem permite que redes residuais profundas, como a ResNet50, com 50 camadas de profundidade, superem as limitações de aprendizado das redes tradicionais. Além da ResNet50, existem variantes como a ResNet101 e a




Figura 24 – Arquitetura de rede VGG19.

ResNet152. A Figura 25 mostra o modelo Resnet50 utilizado nesse estudo, duas camadas totalmente conectadas foram incorporadas: uma com 512 neurônios e outra com 7 neurônios, representando as classes de saída. A primeira camada convolucional possui 64 filtros com um tamanho de kernel de 7×7 , seguida por uma camada de *max pooling* de 3×3 . O primeiro grupo de camadas é composto por três blocos idênticos, enquanto os grupos dois, três e quatro contêm quatro, quatro e três blocos idênticos, respectivamente. Entre alguns dos grupos, as linhas marcadas em azul representam blocos de identidade que conectam camadas de tamanhos diferentes. Após a passagem por todos esses blocos, 38 camadas totalmente conectadas são responsáveis pela tarefa de classificação.




Figura 25 – Arquitetura Resnet50.

4.3 Considerações Finais

Este capítulo descreveu a construção dos conjuntos de dados, detalhando o processo de coleta, o processamento das imagens, as classes resultantes, a quantidade total de imagens obtidas e suas características. Também foram apresentadas as etapas do método

proposto, assim como as arquiteturas dos modelos utilizados CNN, VGG19 e ResNet50, juntamente com os parâmetros ajustados para cada um deles.

5 RESULTADOS

A pesquisa foi desenvolvida em *Python 3.7.13*, utilizando o *Jupyter Notebook* via *Google Cloud Platform* (GCP) como o principal ambiente de desenvolvimento integrado (IDE). A linguagem *Python* foi escolhida pela sua simplicidade e pelas bibliotecas eficientes voltadas para a classificação de imagens, como *TensorFlow* e *Keras*. Neste estudo, utilizamos Redes Neurais Convolucionais e Métodos em Conjunto para avaliar duas abordagens potenciais para identificar doenças do tomateiro, conforme ilustrado na Figura 26. A primeira abordagem, denominada Método A, utiliza as imagens do conjunto de dados TLID, conforme descrito na Seção 4.1.1, e avalia a folha. A segunda abordagem envolve o uso do conjunto de dados PTLID, conforme descrito na Seção 4.1.2. Essa abordagem, conhecida como Método B, avalia a imagem do patch, que se concentra exclusivamente nas regiões da imagem que possuem doenças.




Figura 26 – Métodos utilizados para classificação de doenças do tomateiro.

5.0.1 Método A

O Método A foi conduzido como uma classificação global da folha, conforme ilustrado na Figura 27. Para este processo, utilizamos uma imagem de uma folha de tomate do conjunto de dados TLID, redimensionada para 224×224 pixels, como entrada para a rede.

Diversos modelos de rede foram avaliados, conforme mostrado na Tabela 7. Alguns desses modelos apresentaram desempenho superior a outros. Contudo, a escolha de um modelo com base apenas nos resultados não foi possível, pois o objetivo era testar os mesmos modelos nos conjuntos de dados TLID e PTLID. Nesse contexto, o conjunto de dados PTLID possui uma característica específica: suas imagens têm dimensões de 32×32 pixels. Esse fator impõe um desafio para redes muito profundas, pois possuem muitas camadas de convolução e pooling, que gradualmente reduzem a dimensão espacial (altura e largura) das imagens. Com imagens pequenas como 32×32 , esse processo pode rapidamente reduzir a dimensão a um tamanho tão pequeno que praticamente não resta




Figura 27 – Diagrama de blocos do Método A.

informação útil para a rede processar. Dentre os modelos avaliados, optamos por três: uma CNN customizada, a ResNet50 e a VGG19.

InceptionV3	EfficientNet	Alexnet	CNN customizada	MobileNet	Resnet50	Resnet152V2	VGG19
68,14%	74,80%	78,43%	79,61%	82,69%	82,76%	83,09%	86,56%

Tabela 7 – F-score de redes profundas usando dataset TLID (%)

Analizamos os resultados individuais obtidos a partir dos dados de validação dos três modelos (CNN, VGG-19 e ResNet-50), utilizando duas saídas de rede: Softmax e SVM com valores padrões.

Essa abordagem visou obter um resultado conjunto que superasse a precisão dos métodos isolados. Para isso, utilizamos um conjunto de validação composto por 3.051 imagens.

Também aplicamos aumento de dados neste experimento, pois a diversidade do conjunto de dados pode aumentar a generalização e a robustez do modelo (PULGAR et al., 2017). O tamanho do lote foi definido como 64, e utilizamos o otimizador Adam com uma taxa de aprendizado de 0,0001 para os modelos pré-treinados e 0,001 para a CNN customizada.

A Tabela 8 apresenta os resultados individuais dos três classificadores analisados neste estudo, utilizando métricas de acurácia, precisão, recall e F1 Score. Observamos um equilíbrio nos resultados, com diferenças mínimas entre os métodos. No entanto, os resultados para Softmax superaram os obtidos com SVM. A arquitetura VGG19 alcançou a melhor acurácia, com 86,56%, seguida pela ResNet50, com 82,76%, e, por fim, a CNN específica, com 79,61%.

Para validar a eficácia dos métodos testados, aplicamos os mesmos modelos ao conjunto de dados PlantVillage, em que a acurácia foi superior a 96%. Essas variações de desempenho entre os dois conjuntos de dados, mesmo utilizando o mesmo método, ressaltam as particularidades do novo conjunto de dados apresentado nesta pesquisa.

Em seguida, calculamos a acurácia de cada rede com base nos dados de validação, obtendo resultados para as abordagens de votação Hard e Soft para ambas as saídas da rede. Novamente, a saída Softmax se destacou em relação ao SVM. Conforme mostrado na Tabela 9, o método de votação Hard obteve 85,84%, enquanto o método Soft alcançou 82,76%.

Métricas de Avaliação					
Método	Dataset	Acurácia	Precisão	Recall	F1 Score
CNN+Softmax	TLID	79,61%	79,17%	75,76%	76,63%
VGG19+Softmax	TLID	86,56%	85,10%	84,88%	84,94%
Resnet50+Softmax	TLID	82,76%	80,94%	80,85%	80,80%
CNN+SVM	TLID	66,08%	58,20%	59,56%	57,82%
VGG19+SVM	TLID	82,50%	82,72%	78,98%	79,86%
Resnet50+SVM	TLID	82,63%	82,07%	79,49%	79,97%
CNN+Softmax	PlantVillage	96,95%	96,61%	95,97%	96,23%
VGG19+Softmax	PlantVillage	98,70%	98,43%	98,19%	98,29%
Resnet50+Softmax	PlantVillage	96,18%	96,78%	95,11%	95,70%

Tabela 8 – Resultados dos classificadores individuais Método A e PlantVillage.

Acurácia					
	CNN	VGG19	Resnet50	Hard Voting Ensemble	Soft Voting Ensemble
Softmax	79,61%	86,56%	82,76%	85,84%	82,76%
SVM	66,08%	82,50%	82,63%	84,36%	82,62%

Tabela 9 – Resultados dos classificadores por Votação Método A.

Conforme discutido na Seção 4.1, o banco de dados PlantVillage foi criado a partir de folhas colhidas e fotografadas. Como resultado, características importantes do ambiente de cultivo do tomate podem ter sido negligenciadas, incluindo a presença de diferentes tipos de insetos, partículas, poeira e resíduos de fertilizantes. A ausência desses elementos relevantes nas imagens pode impactar o desempenho do algoritmo, tornando o cenário menos representativo da realidade do cultivo.

O desempenho dos modelos é avaliado com base na acurácia de classificação. Para visualizar esse desempenho, foram geradas matrizes de confusão para os modelos CNN personalizados, VGG19 e ResNet50, conforme ilustrado nas figuras. A Figura 28

representa o modelo CNN customizada, a Figura 29 mostra o comportamento do VGG19, e a Figura 30 apresenta o modelo ResNet50.

A classe que obteve a maior precisão na classificação foi a de folhas saudáveis, pois apresenta pouco ruído. Em contrapartida, classes que combinavam duas doenças frequentemente foram confundidas com aquelas que apresentavam apenas uma. Por exemplo, a classe “Mancha Bacteriana e Minadora” causou confusão entre as classes “Bacterial Mancha Bacteriana” e “Minadora”. Além disso, outras confusões entre classes ocorreram devido às semelhanças entre as doenças em suas diferentes fases. Essas ambiguidades impactaram a precisão dos modelos, resultando em um acurácia abaixo de 86% na votação em conjunto.

True label	0	494 89%	15 4%	7 2%	28 7%	0 0%	4 1%	10 10%
	1	17 3%	350 85%	3 1%	0 0%	32 5%	33 6%	7 7%
	2	2 0%	4 1%	349 76%	5 1%	7 1%	72 14%	1 1%
	3	19 3%	7 2%	10 2%	303 79%	81 13%	3 1%	7 7%
	4	0 0%	7 2%	10 2%	23 6%	452 73%	9 2%	0 0%
	5	0 0%	7 2%	70 15%	1 0%	20 3%	408 77%	0 0%
	6	21 4%	24 6%	8 2%	23 6%	23 4%	2 0%	73 74%
		0	1	2	3	4	5	6
		Predicted label						

Figura 28 – Matriz de confusão Método A - CNN.

5.0.2 Método B

As folhas de tomateiro cultivadas em estufas podem apresentar atributos adicionais, além das doenças presentes, devido às condições ambientais, o que pode comprometer a avaliação geral da folha. O objetivo do Método B é realizar uma avaliação localizada da folha. Para isso, utilizamos os mesmos classificadores do Método A, buscando reduzir o ruído nas imagens ao utilizar patches de 32×32 pixels, onde apenas as doenças específicas estavam visíveis. A Tabela 10 apresenta os resultados obtidos com essas patches, testadas pelos mesmos métodos do Método A, com as saídas de rede Softmax e SVM.

Os resultados indicam que o desempenho dos modelos foi bastante similar; no entanto, quando utilizamos a saída Softmax os resultados foram melhores que o SVM.

True label	0	514 93%	11 2%	11 2%	12 3%	0 0%	1 0%	9 5%
	1	8 1%	396 87%	5 1%	0 0%	12 2%	11 2%	10 6%
	2	5 1%	6 1%	386 80%	5 1%	0 0%	37 8%	1 1%
	3	10 2%	8 2%	14 3%	345 87%	29 6%	1 0%	23 14%
	4	0 0%	13 3%	11 2%	18 5%	446 88%	11 2%	2 1%
	5	0 0%	12 3%	48 10%	0 0%	12 2%	432 88%	2 1%
	6	13 2%	8 2%	8 2%	16 4%	7 1%	0 0%	122 72%
		0	1	2	3	4	5	6
		Predicted label						

Figura 29 – Matriz de confusão Método A - VGG19.

True label	0	486 93%	19 4%	3 1%	41 9%	0 0%	1 0%	8 4%
	1	6 1%	374 85%	3 1%	3 1%	18 3%	20 4%	18 10%
	2	3 1%	4 1%	337 87%	8 2%	4 1%	80 14%	4 2%
	3	11 2%	8 2%	8 2%	335 77%	44 8%	2 0%	22 12%
	4	0 0%	13 3%	3 1%	30 7%	434 83%	8 1%	13 7%
	5	0 0%	8 2%	31 8%	1 0%	17 3%	446 80%	3 2%
	6	18 3%	16 4%	3 1%	16 4%	8 2%	0 0%	113 62%
		0	1	2	3	4	5	6
		Predicted label						

Figura 30 – Matriz de confusão Método A - Resnet50.

O VGG19 obteve a maior acurácia, com 90,19%, seguido pela ResNet50, com 88,94%, e pela CNN personalizada, com 86,78%. Todos os métodos apresentaram uma melhoria significativa em comparação ao Método A, resultado da menor confusão entre as classes. No entanto, ainda é possível observar alguma confusão residual entre as classes, como mostram as matrizes de confusão para CNN a Figura 31, VGG19 a Figura 32 e Resnet50 a Figura 33.

Evaluation Metrics					
Method	Dataset	Accuracy	Precision	Recall	F1 Score
CNN+Softmax	PTLID	86,78%	79,43%	76,18%	77,57%
VGG19+Softmax	PTLID	90,19%	84,90%	81,02%	82,60%
Resnet50+Softmax	PTLID	88,94%	82,18%	78,72%	80,18%
CNN+SVM	PTLID	81,30%	66,57%	58,256%	59,93%
VGG19+SVM	PTLID	78,33%	67,05%	64,53%	64,61%
Resnet50+SVM	PTLID	88,76%	82,51%	77,13%	79,21%

Tabela 10 – Resultados dos classificadores individuais Método B.

Para o método de votação, utilizamos dados de validação com um total de 45.444 imagens. Inicialmente, calculamos a acurácia de cada classificador individualmente. Em seguida, combinamos os três classificadores para determinar a acurácia dos métodos de votação Hard e Soft. A Tabela 11 apresenta os resultados desses dois métodos, com o método Hard obtendo o melhor desempenho geral, alcançando uma acurácia de 90,48%.

Accuracy					
	Hard			Soft	
	CNN	VGG19	Resnet50	Voting Ensemble	Voting Ensemble
Softmax	86,78%	90,19%	88,94%	90,48%	88,94%
SVM	81,30%	78,33%	88,76%	88,81%	88,76%

Tabela 11 – Resultados dos classificadores por Votação Método B.

True label	0	9264 91%	36 2%	27 0%	274 2%	5 0%	9 0%	9 6%	2 0%
	1	42 0%	1387 60%	412 4%	82 1%	113 6%	209 7%	3 2%	0 0%
	2	102 1%	183 8%	9637 86%	331 3%	253 14%	545 19%	5 3%	1 0%
	3	695 7%	119 5%	167 1%	11049 91%	154 9%	33 1%	19 12%	0 0%
	4	24 0%	251 11%	296 3%	274 2%	1164 65%	162 6%	4 2%	0 0%
	5	10 0%	303 13%	645 6%	47 0%	94 5%	1940 67%	1 1%	0 0%
	6	20 0%	25 1%	9 0%	30 0%	9 1%	1 0%	120 75%	0 0%
	7	4 0%	0 0%	0 0%	0 0%	0 0%	0 0%	0 0%	4874 100%
		0	1	2	3	4	5	6	7
Predicted label									

Figura 31 – Matriz de confusão Método B - CNN.

True label	0	9153 96%	18 1%	51 0%	375 3%	9 0%	3 0%	12 7%	5 0%
	1	25 0%	1345 73%	398 3%	86 1%	272 11%	120 5%	2 1%	0 0%
	2	37 0%	151 8%	10168 89%	203 2%	217 9%	278 11%	2 1%	1 0%
	3	337 4%	31 2%	154 1%	11536 92%	154 6%	12 0%	12 7%	0 0%
	4	6 0%	96 5%	162 1%	212 2%	1607 66%	60 2%	2 1%	0 0%
	5	3 0%	180 10%	480 4%	24 0%	183 7%	2170 82%	0 0%	0 0%
	6	12 0%	12 1%	5 0%	43 0%	11 0%	1 0%	130 81%	0 0%
	7	1 0%	0 0%	0 0%	0 0%	0 0%	0 0%	0 0%	4877 100%
		0	1	2	3	4	5	6	7
		Predicted label							

Figura 32 – Matriz de confusão Método B - VGG19.

True label	0	9017 96%	31 1%	44 0%	490 4%	13 1%	8 0%	18 11%	5 0%
	1	22 0%	1475 61%	357 3%	89 1%	142 8%	159 5%	4 2%	0 0%
	2	23 0%	352 15%	9919 88%	197 2%	126 7%	435 15%	4 2%	1 0%
	3	257 3%	84 3%	194 2%	11568 91%	99 6%	21 1%	13 8%	0 0%
	4	9 0%	204 8%	239 2%	282 2%	1271 73%	138 5%	2 1%	0 0%
	5	1 0%	244 10%	504 4%	29 0%	90 5%	2171 74%	1 1%	0 0%
	6	14 0%	21 1%	6 0%	49 0%	4 0%	1 0%	119 74%	0 0%
	7	2 0%	0 0%	0 0%	0 0%	0 0%	0 0%	0 0%	4876 100%
		0	1	2	3	4	5	6	7
		Predicted label							

Figura 33 – Matriz de confusão Método B - Resnet50.

Na etapa seguinte, utilizamos o Método B - Patch Images para testar os modelos considerando a folha inteira. Inicialmente, selecionamos imagens das folhas com dimensões de 256×256 pixels e, em seguida, as dividimos em patches de 32×32 pixels, gerando um total de 64 patches por folha. Esses patches foram então inseridos na CNN customizada e

nas redes pré-treinadas VGG19 e ResNet50. A saída de cada rede é um vetor que contém a contagem de imagens classificadas em cada classe. Nessa classificação, os patches das classes Fundo e Saudável aparecem com maior frequência. A classe Fundo foi descartada no resultado final. A quantidade de vezes que uma classe de doença é identificada no vetor pode indicar o estágio da doença. Após a criação desse vetor, aplicamos os métodos Ensemble Hard e Soft em cada patch, resultando em uma porcentagem de confiança para cada classificação. Por fim, determinamos a qual doença cada patch pertence. O diagrama de blocos ilustrado na Figura 34 descreve o procedimento detalhado.




Figura 34 – Diagrama de blocos de detecção e classificação de doenças foliares locais do tomateiro.

Outro fato interessante observado ao utilizar este método é que o algoritmo consegue encontrar doenças não previamente rotuladas para a folha. Por exemplo, Figura 35 (a) mostra uma imagem rotulada como Mosca Branca, indicada pelas marcas vermelhas na imagem. No entanto, o algoritmo também identificou a doença Oídio, marcada em branco na imagem. Esta doença, no entanto, não havia sido rotulada quando a folha foi avaliada globalmente. A forma como os patches das folhas foram criados permite que o algoritmo identifique outras características com mais detalhes. A classificação dos patches, permite uma classificação mais precisa do tipo de doença, resultando em menos confusão entre as classes como ocorreu no Método A. A Figura 35 (b) mostra a classificação de patches Saudáveis (marcação branca), Mancha Bacteriana (marcação vermelha) e Mancha Bacteriana e Minadora (marcação azul), permitindo maior precisão na identificação de doenças.

Esta classificação local da folha nos permite comprovar visivelmente doenças existentes e evidências de doenças em estágios iniciais, insetos causadores de doenças.

Algumas doenças em estágio inicial são quase imperceptíveis. O Método B permite a classificação precisa de doenças e outras que podem estar em estágios iniciais.




Figura 35 – Exemplos de classificação de imagens usando o Método B.

5.1 Considerações Finais

Nesta sessão, foram apresentados os resultados das simulações utilizando os dois métodos propostos. O desempenho de cada método foi avaliado por meio de métricas como acurácia, matriz de confusão, e classification report. Com base nas métricas analisadas, o Método B demonstrou um desempenho superior ao Método A. Esta classificação de patches nos permite provar doenças visivelmente existentes e evidências de doenças em estágios iniciais, insetos causadores de doenças. Algumas doenças em estágio inicial são quase imperceptíveis. O Método B permite a classificação mais precisa de doenças e outras que podem estar em estágios iniciais.

Em relação às questões de pesquisa, conseguimos chegar às seguintes conclusões:

Q1: *As doenças presentes no cultivo de tomate em estufa têm especificidades regionais?* As doenças são influenciadas pelo clima de cada região. Por exemplo, algumas doenças só ocorrem em clima quente e seco, outras em clima quente e úmido. O clima favorece ou não seu surgimento.

Q2: *Como os algoritmos de identificação se comportam usando imagens não processadas coletadas por smartphones?* Os resultados sugerem que, por não serem processadas, o ruído da imagem se torna mais evidente, dificultando a extração de características e consequentemente contribuindo para que o algoritmo confunda as classes, resultando em desempenho abaixo do esperado.

Q3: *É possível aumentar a precisão na identificação de doenças combinando algoritmos de aprendizado de máquina?* Acreditamos que devido à complexidade do conjunto de dados, os valores quando combinamos os modelos não obtiveram uma melhora tão significativa quanto quando avaliados separadamente. No Método A, podemos ver que a precisão da classificação para o Ensemble Voting Hard atingiu 85,84%, menor que o maior valor alcançado pelo membro do ensemble VGG19. Para o Ensemble Voting Soft, o valor alcançado foi de 82,76%, valor menor que o maior valor alcançado por um dos membros do ensemble. Ao avaliar o Método B, notamos que os valores do Ensemble Voting Hard aumentaram levemente em comparação ao maior valor obtido individualmente pelos modelos. O Ensemble Voting Soft obteve valor igual apenas para um dos membros do ensemble.

Q4: *É possível identificar a presença de múltiplas doenças em folhas de tomateiro e seu grau de contaminação usando estratégias baseadas em aprendizado de máquina?* A complexidade do banco de dados, como as características semelhantes entre as doenças avaliadas em suas diferentes fases, permitiu verificar, de acordo com as matrizes de confusão dos modelos avaliados, que havia muita confusão entre as classes. O Método B reduziu a confusão entre as classes. Quando testado com o tamanho total da folha (256×256), permitiu não apenas encontrar a doença esperada, mas também identificar outras doenças existentes na folha. Quando analisamos a folha globalmente com o Método B, também é possível analisar o estágio em que a doença está com base no número de patches de doença encontradas na folha.

6 CONCLUSÃO E TRABALHOS FUTUROS

Este estudo propõe identificar os modelos de aprendizado de máquina mais eficazes para reconhecer doenças foliares em tomates cultivados em estufas, utilizando uma nova base de dados coletada especificamente em uma região do Paraná. Foram utilizados dois métodos de avaliação, cada um considerando um tamanho de imagem diferente: o Método A, que utilizou o conjunto TLID com imagens de 256×256 pixels, e o Método B, que utilizou o PTLID, composto por imagens de 32×32 pixels. Ambos os conjuntos incluem imagens de folhas saudáveis e de seis classes de folhas doentes, sendo um diferencial a coleta das imagens sem exclusão de características específicas das folhas, preservando detalhes importantes para a identificação das doenças. Os dois métodos foram testados em três modelos de redes neurais convolucionais profundas: uma CNN personalizada e duas redes pré-treinadas, a VGG19 e a ResNet50, além da aplicação de um método de votação em conjunto. Os resultados mostraram que o desempenho do Método A, com imagens maiores do TLID, foi inferior ao do Método B, que utilizou imagens menores do PTLID, sugerindo que a análise de doenças em imagens feita localmente facilita a distinção entre as classes. Entre os modelos avaliados individualmente, a VGG19 apresentou o melhor desempenho em ambos os conjuntos de dados. Adicionalmente, a aplicação do método de votação proporcionou um ganho modesto nas taxas de acurácia. Para trabalhos futuros, pretendemos desenvolver técnicas de segmentação de imagens para reduzir o ruído e aprimorar a precisão no reconhecimento das doenças, além de expandir a abordagem para outras culturas, tanto em estufas quanto em campo aberto. Planejamos também explorar o uso de classificadores multirrótulo, considerando que múltiplas doenças podem estar presentes simultaneamente em uma única amostra.

REFERÊNCIAS

AHMED, Kawcher; SHAHIDI, Tasmia Rahman; ALAM, Syed Md. Irfanul; MOMEN, Sifat. Rice leaf disease detection using machine learning techniques. In: *2019 International Conference on Sustainable Technologies for Industry 4.0 (STI)*. [S.l.: s.n.], 2019. p. 1–5. Citado 2 vezes nas páginas 24 e 29.

ANGELOTTI F., Ghini R.; BETTIOL, W. *Como o aumento da temperatura interfere nas doenças de plantas*. Brasília: Embrapa., 2017. 116 p. Citado na página 17.

BARBEDO, Jayme G.A. Factors influencing the use of deep learning for plant disease recognition. *Biosystems Engineering*, v. 172, p. 84–91, 2018. ISSN 1537-5110. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1537511018303027>>. Citado na página 46.

BOULEY, Timothy; GILBERTO, Marius; WHUNG, Pai-Yei; GALL, François Le; PLANTE, Caroline. *The World Bank Reducing Climate-Sensitive Risks*. (accessed on 28 March 2022). 2014. Disponível em: <<https://documents.worldbank.org/en/publication/documents-reports/documentdetail/486511468167944431/reducing-climate-sensitive-disease-risks>>. Citado na página 17.

BRAHIMI, Mohammed; KAMEL, Boukhalfa; MOUSSAOUI, Abdelouahab. Deep learning for tomato diseases: Classification and symptoms visualization. *Applied Artificial Intelligence*, v. 31, p. 1–17, 05 2017. Citado 2 vezes nas páginas 25 e 30.

BROWN, Sara. *Machine Learning, explained*. 2021. Disponível em: <<https://mitsloan.mit.edu/ideas-made-to-matter/machine-learning-explained>>. Citado na página 31.

BURKA, Dávid; PUPPE, Clemens; SZEPEŠVÁRY, László; TASNÁDI, Attila. Voting: A machine learning approach. *European Journal of Operational Research*, v. 299, n. 3, p. 1003–1017, 2022. ISSN 0377-2217. Citado na página 39.

CHINNAMGARI, S.K. *R Machine Learning Projects: Implement supervised, unsupervised, and reinforcement learning techniques using R 3.5*. Packt Publishing, 2019. ISBN 9781789806090. Disponível em: <<https://books.google.com.br/books?id=4dKDDwAAQBAJ>>. Citado na página 32.

Corporation Microsoft. *Paint 3D*. 2019. Computer Software. Disponível em: <<https://apps.microsoft.com/store/detail/paint-3d/9NBLGGH5FV99?hl=pt-br&gl=BR>>. Citado na página 47.

CRAMMER, Koby; SINGER, Yoram; CRISTIANINI, Nello; SHAWE-TAYLOR, John; WILLIAMSON, Bob. On the algorithmic implementation of multiclass kernel-based vector machines. *J. Mach. Learn. Res.*, v. 2, 01 2002. Citado na página 39.

CRUZ, Yarens J.; RIVAS, Marcelino; QUIZA, Ramón; VILLALONGA, Alberto; HABER, Rodolfo E.; BERUVIDES, Gerardo. Ensemble of convolutional neural networks based on an evolutionary algorithm applied to an industrial welding process. *Computers in Industry*, v. 133, p. 103530, 2021. ISSN 0166-3615. Citado na página 40.

- D'ADDONA, Doriana Marilena. Neural network. In: _____. *CIRP Encyclopedia of Production Engineering*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2014. p. 911–918. ISBN 978-3-642-20617-7. Disponível em: <https://doi.org/10.1007/978-3-642-20617-7_6563>. Citado na página 32.
- DAMICONE, J.; BRANDENBERGER, L. *Common Diseases of Tomatoes- Part II: Diseases Caused by Bacteria, Viruses and Nematodes*. 2017. Disponível em: <<https://extension.okstate.edu/fact-sheets/common-diseases-of-tomatoes-part-ii-diseases-caused-by-bacteria-viruses-and-nematodes.html>>. Citado na página 43.
- DAVID, Hepzibah; RAMALAKSHMI, K.; RAMACHANDRAN, Venkatesan; HEMALATHA, G. Tomato leaf disease detection using hybrid cnn-rnn model. In: _____. [S.l.: s.n.], 2021. ISBN 9781643682020. Citado 2 vezes nas páginas 27 e 30.
- DONG, Z. Yu X.; CAO, Y. Shi W.; MA, Q. A survey on ensemble learning. In: *Front. Comput. Sci.* [S.l.: s.n.], 2020. p. 241–258. Citado na página 39.
- DURMUS, Halil; GUNES, Ece Olcay; KIRCI, Mürvet. Disease detection on the leaves of the tomato plants by using deep learning. In: *2017 6th International Conference on Agro-Geoinformatics*. [S.l.: s.n.], 2017. p. 1–5. Citado 3 vezes nas páginas 25, 30 e 34.
- FAROOQ, Muhammad Shoaib; RIAZ, Shamilya; ABID, Adnan; ABID, Kamran; NAEEM, Muhammad Azhar. A survey on the role of iot in agriculture for the implementation of smart farming. *IEEE Access*, v. 7, p. 156237–156271, 2019. Citado na página 17.
- GADADE, H. D.; KIRANGE, D. K. Machine learning based identification of tomato leaf diseases at various stages of development. In: *2021 5th International Conference on Computing Methodologies and Communication (ICCMC)*. [S.l.: s.n.], 2021. p. 814–819. Citado 2 vezes nas páginas 27 e 30.
- GEHLOT, Mamta; SAINI, Madan Lal. Analysis of different cnn architectures for tomato leaf disease classification. In: *2020 5th IEEE International Conference on Recent Advances and Innovations in Engineering (ICRAIE)*. [S.l.: s.n.], 2020. p. 1–6. Citado 2 vezes nas páginas 26 e 30.
- GHINI R., Hamada E. Bettiol W. *Impactos das mudanças climáticas sobre doenças de importantes culturas no Brasil*. [S.l.]: Embrapa Meio Ambiente, 2011. Citado na página 17.
- HE, Kaiming; ZHANG, Xiangyu; REN, Shaoqing; SUN, Jian. Deep residual learning for image recognition. In: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. [S.l.: s.n.], 2016. p. 770–778. Citado na página 55.
- HONG, Huiqun; LIN, Jinfa; HUANG, Fenghua. Tomato disease detection and classification by deep learning. In: *2020 International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE)*. [S.l.: s.n.], 2020. p. 25–29. Citado 2 vezes nas páginas 26 e 30.
- HUGHES, David P.; SALATHÉ, Marcel. An open access repository of images on plant health to enable the development of mobile disease diagnostics through machine learning and crowdsourcing. *CoRR*, abs/1511.08060, 2015. Disponível em: <<http://arxiv.org/abs/1511.08060>>. Citado 3 vezes nas páginas 25, 26 e 44.

- IBGE, Instituto Brasileiro de Geografia e Estatística. *Levantamento Sistemático da Produção Agrícola*. 2021. Disponível em: <https://biblioteca.ibge.gov.br/visualizacao/periodicos/2415/epag_2021_jan.pdf>. Citado na página 18.
- IGUAL, Laura; SEGU, Santi; VITRI, Jordi; PUERTAS, Eloi; RADEVA, Petia; PUJOL, Oriol; ESCALERA, Sergio; DANT, Francesc; GARRIDO, Llus. *Introduction to Data Science: A Python Approach to Concepts, Techniques and Applications*. 1st. ed. [S.l.]: Springer Publishing Company, Incorporated, 2017. ISBN 3319500163. Citado na página 37.
- ISLAM, M.P.; HATOU, K.; AIHARA, T.; SENO, S.; KIRINO, S.; OKAMOTO, S. Performance prediction of tomato leaf disease by a series of parallel convolutional neural networks. *Smart Agricultural Technology*, v. 2, p. 100054, 2022. ISSN 2772-3755. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2772375522000193>>. Citado na página 27.
- JAIN, Naman. *Optimization of Regularization and Early Stopping to Reduce Overfitting in Recognition of Handwritten Characters*. 2020. Citado na página 37.
- KAMIENSKI, Carlos; SOININEN, Juha-Pekka; TAUMBERGER, Markus; DANTAS, Ramide; TOSCANO, Attilio; CINOTTI, Tullio Salmon; MAIA, Rodrigo Filev; NETO, André Torre. Smart water management platform: Iot-based precision irrigation for agriculture. *Sensors*, v. 19, n. 2, 2019. ISSN 1424-8220. Disponível em: <<https://www.mdpi.com/1424-8220/19/2/276>>. Citado na página 23.
- KANSTRÉN, Teemu. *A Look at Precision, Recall, and F1-Score Exploring the relations between machine learning metrics*. 2020. Disponível em: <<https://towardsdatascience.com/a-look-at-precision-recall-and-f1-score-36b5fd0dd3ec>>. Citado na página 37.
- KAYETHA, Spandana; PABBOJU, Suresh. Applications of iot for soil quality. In: _____. [S.l.: s.n.], 2020. p. 277–286. ISBN 978-981-13-8460-8. Citado na página 17.
- KHALID, Aima; AKBAR, Shahzad; HASSAN, Syed Ale; FIRDOUS, Saba; GULL, Sahar. Detection of tomato leaf disease using deep convolutional neural networks. In: *2023 4th International Conference on Advancements in Computational Sciences (ICACS)*. [S.l.: s.n.], 2023. p. 1–6. Citado 2 vezes nas páginas 28 e 30.
- KHAN, Fazeel; ABUBAKAR, Adamu; ZEKI, Akram. Environmental monitoring and disease detection of plants in smart greenhouse using internet of things. *Journal of Physics Communications*, v. 4, 05 2020. Citado na página 17.
- KHANNA, Abhishek; KAUR, Sanmeet. Evolution of internet of things (iot) and its significant impact in the field of precision agriculture. *Computers and Electronics in Agriculture*, v. 157, p. 218–231, 2019. ISSN 0168-1699. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0168169918316417>>. Citado na página 17.
- KITPO, Nuttakarn; KUGAI, Yosuke; INOUE, Masahiro; YOKEMURA, Taketoshi; SATOMURA, Shinichi. Internet of things for greenhouse monitoring system using deep learning and bot notification services. In: *2019 IEEE International Conference on Consumer Electronics (ICCE)*. [S.l.: s.n.], 2019. p. 1–4. Citado na página 17.

- KRIZHEVSKY, Alex; SUTSKEVER, Ilya; HINTON, Geoffrey E. Imagenet classification with deep convolutional neural networks. In: PEREIRA, F.; BURGESS, C.J.; BOTTOU, L.; WEINBERGER, K.Q. (Ed.). *Advances in Neural Information Processing Systems*. Curran Associates, Inc., 2012. v. 25. Disponível em: <<https://proceedings.neurips.cc/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf>>. Citado na página 35.
- KUMARI, Ch. Usha; PRASAD, S. Jeevan; MOUNIKA, G. Leaf disease detection: Feature extraction with k-means clustering and classification with ann. In: *2019 3rd International Conference on Computing Methodologies and Communication (ICCMC)*. [S.l.: s.n.], 2019. p. 1095–1098. Citado na página 24.
- LEITE, Germano Leão Demolin; FIALHO, Amanda. Chapter 14 - protection of tomatoes using bagging technology and its role in ipm of arthropod pests. In: WAKIL, Waqas; BRUST, Gerald E.; PERRING, Thomas M. (Ed.). *Sustainable Management of Arthropod Pests of Tomato*. San Diego: Academic Press, 2018. p. 305–311. ISBN 978-0-12-802441-6. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B9780128024416000140>>. Citado na página 18.
- LI, Zewen; YANG, Wenjie; PENG, Shouheng; LIU, Fan. A survey of convolutional neural networks: Analysis, applications, and prospects. *CoRR*, abs/2004.02806, 2020. Disponível em: <<https://arxiv.org/abs/2004.02806>>. Citado na página 35.
- LIJUAN, Tan; JINZHU, Lu; HUANYU, Jiang. Tomato leaf diseases classification based on leaf images: A comparison between classical machine learning and deep learning methods. *AgriEngineering*, v. 3, n. 3, p. 542–558, 2021. ISSN 2624-7402. Disponível em: <<https://www.mdpi.com/2624-7402/3/3/35>>. Citado 2 vezes nas páginas 27 e 30.
- LIMA, Tiago Costa. Desafios no controle de moscas-minadoras em tomateiro. v. 2, p. 14–16, 04 2019. Citado na página 44.
- LOPES, Carlos Alberto; AVILA, Antonio Carlos de. *Doenças do tomateiro*. Brasília-DF: [s.n.], 2005. 151 p. ISBN 85-86413-05-4. Citado 7 vezes nas páginas 17, 18, 41, 42, 43, 44 e 48.
- MAHESH, Batta. Machine learning algorithms -a review. 01 2019. Citado na página 31.
- MALUNAO, Dennis C.; TAMARGO, Roger S.; SANDIL, Ricky C.; CUNANAN, Christopher Franco; MERIN, Jovencio V.; JALLORINA, Roldan D. Deep convolutional neural networks-based machine vision system for detecting tomato leaf disease. In: *2022 IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT)*. [S.l.: s.n.], 2022. p. 1–5. Citado 2 vezes nas páginas 28 e 30.
- MEERADEVI, V; RANJANA, Mundada; MONICA, R Sawkar; SOUMYA, P Bellad; RITHIKA S KEERTHI, Poornimas. Design and development of efficient techniques for leaf disease detection using deep convolutional neural networks. In: *2020 IEEE International Conference on Distributed Computing, VLSI, Electrical Circuits and Robotics (DISCOVER)*. [S.l.: s.n.], 2020. p. 153–158. Citado 2 vezes nas páginas 26 e 30.
- NATIONS, United. *Population*. 2022. Disponível em: <<https://www.un.org/en/global-issues/population>>. Citado na página 17.

NAVARRO, Emerson; COSTA, Nuno; PEREIRA, António. A systematic review of iot solutions for smart farming. *Sensors*, v. 20, n. 15, 2020. ISSN 1424-8220. Disponível em: <<https://www.mdpi.com/1424-8220/20/15/4231>>. Citado na página 17.

OMAR, Shriya; JAIN, Rachna; BALI, Vikram. Leaf disease detection using convolutional neural network. In: *2022 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COM-IT-CON)*. [S.l.: s.n.], 2022. v. 1, p. 53–56. Citado 2 vezes nas páginas 28 e 30.

O'SHEA, Keiron; NASH, Ryan. *An Introduction to Convolutional Neural Networks*. arXiv, 2015. Disponível em: <<https://arxiv.org/abs/1511.08458>>. Citado 2 vezes nas páginas 34 e 36.

PERNAPATI, Kiranmai. Iot based low cost smart irrigation system. In: *2018 Second International Conference on Inventive Communication and Computational Technologies (ICICCT)*. [S.l.: s.n.], 2018. p. 1312–1315. Citado 2 vezes nas páginas 17 e 23.

PITAKPHONGMETHA, Jumras; BOONNAM, Nathaphon; WONGKOON, Siriwan; HORANONT, Teerayut; SOMKIADCHAROEN, Deeprom; PRAPAKORNPILAI, Jiranuwat. Internet of things for planting in smart farm hydroponics style. In: *2016 International Computer Science and Engineering Conference (ICSEC)*. [S.l.: s.n.], 2016. p. 1–5. Citado na página 17.

PRADHAN, Priyanka; KUMAR, Brajesh. Automatic detection of tomato diseases using fine-tuned pre-trained deep learning models. In: *2022 3rd International Conference for Emerging Technology (INCET)*. [S.l.: s.n.], 2022. p. 1–5. Citado 2 vezes nas páginas 28 e 30.

PRATISSOLI, D.; CARVALHO, J. R.; PASTORIREGIANE, P. L.; O.FREITAS, C.; ZAGO, B. H. B. Incidência de mosca-minadora e insetos vetores em sistemas de manejo de pragas em tomateiro. *Rev. Ciênc. Agron.*, v. 46, n. 3, p. 26–36, July 2015. Citado na página 44.

PULGAR, Francisco J.; RIVERA, Antonio J.; CHARTE, Francisco; JESUS, María J. del. On the impact of imbalanced data in convolutional neural networks performance. In: PISÓN, Francisco Javier Martínez de; URRACA, Rubén; QUINTIÁN, Héctor; CORCHADO, Emilio (Ed.). *Hybrid Artificial Intelligent Systems*. Cham: Springer International Publishing, 2017. p. 220–232. Citado na página 59.

PUSHPA, B R; ASHOK, Adarsh; V, Shree Hari A. Plant disease detection and classification using deep learning model. In: *2021 Third International Conference on Inventive Research in Computing Applications (ICIRCA)*. [S.l.: s.n.], 2021. p. 1285–1291. Citado 2 vezes nas páginas 27 e 30.

RAMESH, Shima; HEBBAR, Ramachandra; M., Niveditha; R., Pooja; N., Prasad Bhat; N., Shashank; P.V., Vinod. Plant disease detection using machine learning. In: *2018 International Conference on Design Innovations for 3Cs Compute Communicate Control (ICDI3C)*. [S.l.: s.n.], 2018. p. 41–45. Citado na página 24.

RAVA, C. A.; SARTORATO, A. *Conceitos Básicos Sobre Doenças De PLantas*. 1994. Disponível em: <<https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/199892/1/CNPAF1994p7.pdf>>. Citado na página 41.

- ROY, Debashish; SRIVASTAVA, Rajeev; JAT, Mansi; KARACA, Mustafa Said. A complete overview of analytics techniques: Descriptive, predictive, and prescriptive. In: _____. *Decision Intelligence Analytics and the Implementation of Strategic Business Management*. Cham: Springer International Publishing, 2022. p. 15–30. Disponível em: <https://doi.org/10.1007/978-3-030-82763-2_2>. Citado na página 31.
- SAKKARVARTHI, Gnanavel; SATHIANESAN, Godfrey Winster; MURUGAN, Vetri Selvan; REDDY, Avulapalli Jayaram; JAYAGOPAL, Prabhu; ELSISI, Mahmoud. Detection and classification of tomato crop disease using convolutional neural network. *Electronics*, v. 11, n. 21, 2022. ISSN 2079-9292. Disponível em: <<https://www.mdpi.com/2079-9292/11/21/3618>>. Citado 2 vezes nas páginas 28 e 30.
- SANTOS, Claudio Filipi Gonçalves dos; PAPA, João Paulo. Avoiding overfitting: A survey on regularization methods for convolutional neural networks. *ACM Computing Surveys*, Association for Computing Machinery (ACM), jan 2022. Disponível em: <[https://doi.org/10.1145%2F3510413](https://doi.org/10.1145/2F3510413)>. Citado na página 36.
- SARDOGAN, Melike; TUNCER, Adem; OZEN, Yunus. Plant leaf disease detection and classification based on cnn with lvq algorithm. In: *2018 3rd International Conference on Computer Science and Engineering (UBMK)*. [S.l.: s.n.], 2018. p. 382–385. Citado 2 vezes nas páginas 25 e 30.
- SHARMA, Pushkara; HANS, Pankaj; GUPTA, Subhash Chand. Classification of plant leaf diseases using machine learning and image preprocessing techniques. In: *2020 10th International Conference on Cloud Computing, Data Science Engineering (Confluence)*. [S.l.: s.n.], 2020. p. 480–484. Citado 2 vezes nas páginas 26 e 30.
- SHORTEN, C.; KHOSHGOFTAAR, T.M. A survey on image data augmentation for deep learning. *J Big Data*, v. 6, n. 60, 2019. Citado na página 37.
- SHRESTHA, Ajay; MAHMOOD, Ausif. Review of deep learning algorithms and architectures. *IEEE Access*, v. 7, p. 53040–53065, 2019. Citado na página 32.
- SIMONYAN, Karen; ZISSERMAN, Andrew. *Very Deep Convolutional Networks for Large-Scale Image Recognition*. arXiv, 2014. Disponível em: <<https://arxiv.org/abs/1409.1556>>. Citado na página 55.
- SPANDANA, K.; PABBOJU, Suresh. Applications of iot for soil quality. In: GUNJAN, Vinit Kumar; DIAZ, Vicente Garcia; CARDONA MANUELAND SOLANKI, Vijender Kumar; SUNITHA, K. V. N. (Ed.). *ICICCT 2019 – System Reliability, Quality Control, Safety, Maintenance and Management*. Singapore: Springer Singapore, 2020. p. 277–286. ISBN 978-981-13-8461-5. Citado na página 23.
- SRIVASTAVA, Nitish; HINTON, Geoffrey; KRIZHEVSKY, Alex; SUTSKEVER, Ilya; SALAKHUTDINOV, Ruslan. Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, v. 15, n. 56, p. 1929–1958, 2014. Disponível em: <<http://jmlr.org/papers/v15/srivastava14a.html>>. Citado na página 37.
- TANEJA, Mohit; BYABAZAIRE, John; DAVY, Alan; OLARIU, Cristian. Fog assisted application support for animal behaviour analysis and health monitoring in dairy farming. In: *2018 IEEE 4th World Forum on Internet of Things (WF-IoT)*. [S.l.: s.n.], 2018. p. 819–824. Citado na página 17.

- TARIK, Marjanul Islam; AKTER, Sadia; MAMUN, Abdullah Al; SATTAR, Abdus. Potato disease detection using machine learning. In: *2021 Third International Conference on Intelligent Communication Technologies and Virtual Mobile Networks (ICICV)*. [S.l.: s.n.], 2021. p. 800–803. Citado 2 vezes nas páginas 25 e 29.
- TM, Prajwala; PRANATHI, Alla; SAIASHRITHA, Kandiraju; CHITTARAGI, Nagaratna B.; KOOLAGUDI, Shashidhar G. Tomato leaf disease detection using convolutional neural networks. In: *2018 Eleventh International Conference on Contemporary Computing (IC3)*. [S.l.: s.n.], 2018. p. 1–5. Citado 2 vezes nas páginas 26 e 30.
- TRAN, Trung-Tin; CHOI, Jae-Won; LE, Thien-Tu Huynh; KIM, Jong-Wook. A comparative study of deep cnn in forecasting and classifying the macronutrient deficiencies on development of tomato plant. *Applied Sciences*, v. 9, n. 8, 2019. ISSN 2076-3417. Disponível em: <<https://www.mdpi.com/2076-3417/9/8/1601>>. Citado na página 24.
- TURKOGLU, Muammer; YANIKOGLU, Berrin; HANBAY, Davut. Plantdiseasenet: convolutional neural network ensemble for plant disease and pest detection. *Signal, Image and Video Processing*, v. 16, p. 1–9, 03 2022. Citado 2 vezes nas páginas 28 e 30.
- VAPNIK, V. *The nature of statistical learning theory*. Berlin: Springer, 1995. Citado na página 39.
- VELASCO, Juan Núñez; FONTHAL, Faruk; L., Yasmin Quezada. Design and implementation of wsn and iot for precision agriculture in tomato crops. In: . [S.l.: s.n.], 2018. p. 1–5. Citado na página 17.
- VELÁSQUEZ, André C et al. “plant-pathogen warfare under changing climate conditions.”. In: . [S.l.: s.n.], 2018. v. 28, p. 10. Citado na página 41.
- VERMA, Shradha; CHUG, Anuradha; SINGH, Amit. Application of convolutional neural networks for evaluation of disease severity in tomato plant. *Journal of Discrete Mathematical Sciences and Cryptography*, v. 23, p. 273–282, 01 2020. Citado na página 26.
- VK SINGH AK, Kumar A. Singh. Disease management of tomato through pgpb: current trends and future perspective. *3 Biotech*, v. 7, n. 7, p. 2–10, Aug 2017. Citado na página 41.
- YING, Xue. An overview of overfitting and its solutions. *Journal of Physics: Conference Series*, IOP Publishing, v. 1168, p. 022022, feb 2019. Disponível em: <<https://doi.org/10.1088/1742-6596/1168/2/022022>>. Citado na página 36.