



UFMA



UFPI



UFC



UFERSA



UFRN



UFPB



UFPE



UFS



UESC

UNIVERSIDADE FEDERAL DE SERGIPE

PROGRAMA DE DOUTORADO EM DESENVOLVIMENTO E MEIO
AMBIENTE

ASSOCIAÇÃO PLENA EM REDE

REDES NEURAIS CONVOLUCIONAIS E PREVISÃO CLIMÁTICA NO
MONITORAMENTO E MANEJO DA CERCOSPORIOSE EM CULTURAS
DE PIMENTA

DOUGLAS VIEIRA LEITE

SÃO CRISTÓVÃO

2026

**FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA CENTRAL
UNIVERSIDADE FEDERAL DE SERGIPE**

L533r Leite, Douglas Vieira.
 Redes neurais convolucionais e previsão climática no
 monitoramento e manejo da cercosporiose em culturas de
 pimenta / Douglas Vieira Leite; orientador Gregorio Guirada
 Faccioli. – São Cristóvão, SE, 2026.
 203 f. : il.

 Tese (doutorado em Desenvolvimento e meio ambiente) –
 Universidade Federal de Sergipe, 2026.

 1. Meio ambiente. 2. Agricultura de precisão. 3. Sigatoka, Mal de.
 4. Fungos fitopatogênicos. 5. Redes neurais (Computação). I.
 Faccioli, Gregorio Guirada, orient. II. Título.

CDU 502.1:631

DOUGLAS VIEIRA LEITE

**REDES NEURAIS CONVOLUCIONAIS E PREVISÃO CLIMÁTICA NO
MONITORAMENTO E MANEJO DA CERCOSPORIOSE EM CULTURAS
DE PIMENTA**

Tese apresentada ao Programa de Doutorado em Desenvolvimento e Meio Ambiente (PRODEMA), Associação Plena em Rede, da Universidade Federal de Sergipe (UFS), como requisito para obtenção do título de Doutor em Desenvolvimento e Meio Ambiente.

Orientador: Prof. Dr. Gregorio Guirado Faccioli

Co-orientador: Prof. Dr. Alisson Vasconcelos de Brito

SÃO CRISTÓVÃO

2026

DOUGLAS VIEIRA LEITE

**REDES NEURAIS CONVOLUCIONAIS E PREVISÃO CLIMÁTICA NO
MONITORAMENTO E MANEJO DA CERCOSPORIOSE EM CULTURAS
DE PIMENTA**

Tese apresentada ao Programa de Doutorado em Desenvolvimento e Meio Ambiente (PRODEMA), Associação Plena em Rede, da Universidade Federal de Sergipe (UFS), como requisito para obtenção do título de Doutor em Desenvolvimento e Meio Ambiente.

Linha de Pesquisa: Tecnologias para o desenvolvimento sustentável

Defendida em: 23 / 02 / 2026.

Documento assinado digitalmente
 **DOUGLAS VIEIRA LEITE**
Data: 15/04/2026 14:41:54-0300
Verifique em <https://validar.iti.gov.br>

Douglas Vieira Leite
Candidato

BANCA EXAMINADORA

Documento assinado digitalmente
 **GREGORIO GUIRADA FACCIOLI**
Data: 15/04/2026 15:33:19-0300
Verifique em <https://validar.iti.gov.br>

Gregorio Guirado Faccioli, Prof. Dr. (UFS)
Presidente - Orientador

Documento assinado digitalmente
 **ALISSON VASCONCELOS DE BRITO**
Data: 17/04/2026 15:59:54-0300
Verifique em <https://validar.iti.gov.br>

Alisson Vasconcelos de Brito, Prof. Dr. (UFPB)
Co-orientador

Raimundo Rodrigues Gomes Filho, Prof. Dr. (UFS)

Examinador - Representante local do PRODEMA

Inajá Francisco de Souza, Prof. Dr. (UFS)

Examinadora – Representante da Rede PRODEMA

Rubens de Souza Matos Júnior, Prof. Dr. (IFS)

Examinador – Representante de instituição externa à Rede PRODEMA

Juan Mariano Camarillo, Prof. Dr. (University of Seville)

Examinador – Representante de instituição externa à Rede PRODEMA

AGRADECIMENTOS

Agradeço primeiramente ao meu núcleo familiar. À minha esposa e aos meus dois filhos, que acompanharam esta jornada desde o início com companheirismo, paciência e apoio. Agradeço também aos meus pais e irmãos pelos incentivos durante toda a minha carreira acadêmica.

Agradeço ao meu orientador, Prof. Dr. Gregorio Guirado Faccioli, pela atenção desde o primeiro contato para a seleção do doutorado, mostrando-se sempre solícito e aconselhando da melhor forma a condução do trabalho.

Agradeço ao meu coorientador, Prof. Dr. Alisson Vasconcelos de Brito, pela indicação dos melhores caminhos, principalmente na fase inicial do desenvolvimento desta pesquisa.

Agradeço aos parceiros da CODERSE (Companhia de Desenvolvimento Regional de Sergipe), em especial a Marcos Emílio Almeida, pela recepção e introdução ao Perímetro Irrigado Piauí e pela facilitação do contato com os produtores da região.

Agradeço à FAPITEC (Fundação de Apoio à Pesquisa e à Inovação Tecnológica do Estado de Sergipe) pela bolsa de doutorado concedida, que, por meio desse incentivo, me permitiu realizar um trabalho de melhor qualidade.

Agradeço ao IFS (Instituto Federal de Sergipe), minha casa, pela concessão de afastamento remunerado para a dedicação integral a este trabalho. Acredito que isso possibilitou o desenvolvimento de uma pesquisa mais aprofundada, gerando muitos frutos positivos.

*“O impedimento à ação avança a ação. O que permanece
no caminho torna-se o caminho.”*

— Marco Aurélio

Sumário

1	INTRODUÇÃO GERAL	18
2	FUNDAMENTAÇÃO TEÓRICA	21
2.1	Desenvolvimento Sustentável e Agricultura	21
2.2	Agricultura 4.0 e Tecnologias Digitais	23
2.3	Doenças de Plantas e Avaliação de Severidade	24
2.4	Redes Neurais Convolucionais e Visão Computacional	26
2.4.1	Arquiteturas para Segmentação de Instâncias	28
2.5	Previsão Meteorológica e Manejo de Doenças	30
2.6	Agricultura Familiar e Acessibilidade Tecnológica	32
3	MATERIAIS E MÉTODOS	34
3.1	Revisão Sistemática da Literatura (Artigo I)	34
3.2	Desenvolvimento e Validação de Modelos CNN (Artigo II) . . .	35
3.3	Desenvolvimento de Sistema Integrado de Apoio à Decisão (Artigo III)	36
3.4	Engajamento Comunitário e Transferência de Conhecimento (Artigo IV)	37
3.5	Integração Metodológica	38
	Referências	38
	CAPÍTULO I	45
	Avanços e perspectivas na Utilização de Redes Neurais Convolucionais para Avaliação da Severidade de Doenças em Plantas: Uma Revisão Sistemática	45
1	Introdução	48
2	Trabalhos relacionados	50
2.1	Necessidade de uma revisão	52
3	Redes Neurais Convolucionais	52
3.1	Modelos e treinamento	53
4	Método de Pesquisa	55
4.1	Planejamento da revisão	57
4.1.1	Objetivos da revisão e questões de pesquisa	57
4.2	Condução da revisão	57
4.2.1	Critérios de Busca	57
4.2.2	Critérios de Inclusão e Exclusão	58

4.2.3	Busca e Seleção dos Estudos	59
4.2.4	Extração e Síntese de Dados	59
4.2.5	Avaliação de Qualidade	60
5	Resultados da revisão	62
5.1	Visão geral	62
5.2	Abordagens gerais para avaliação da severidade de doenças de plantas usando CNN	64
5.3	RQ1: Como os datasets foram montados para o treinamento do modelo?	67
5.4	RQ2: Quais métricas foram aplicadas para avaliar os modelos de CNN?	68
5.5	RQ3: Quais métodos, parâmetros de treinamento e arquiteturas de CNN foram utilizados por pesquisadores para avaliar a severidade de doenças em plantas, e quais foram seus resultados?	70
5.5.1	<i>Frameworks</i> clássicos	70
5.5.2	<i>Frameworks</i> aprimorados e híbridos	71
5.5.3	Transferência de Aprendizado, Lógica Fuzzy, Imagens Multiespec- trais e Utilização de GAN	77
5.5.4	Parâmetros de treinamento	78
5.5.5	Pesquisa recente	79
5.6	RQ4: Quais foram os desafios no desenvolvimento da pesquisa?	79
5.6.1	Desafios relacionados à doença	79
5.6.2	Desafios relacionados ao conjunto de dados	80
5.6.3	Desafios no desempenho do modelo	80
5.7	RQ5: Quais são as sugestões para trabalhos futuros?	81
6	Conclusão	89
	Referências	89

CAPÍTULO II 106

Modelos de Aprendizado Profundo para Detecção e Avaliação de Se- veridade da Mancha de Cercospora (<i>Cercospora capsici</i>) em Pimentas sob Condições Naturais	106
1	Introdução 109
2	Modelos de Aprendizado Profundo 111
2.1	YOLOv8 111
2.2	Mask R-CNN 112
3	Materiais e Métodos 113
3.1	Aquisição do conjunto de dados (dataset) e preparação 113
3.2	Modelos e Treinamento 115

3.3	Threshold de Confiança de Inferência (CT)	116
3.4	Determinação da Severidade	116
3.5	Classificação do Nível de Severidade	117
3.6	Métricas de Avaliação	117
3.6.1	Métricas de Avaliação no Nível de Pixel	118
3.6.2	Métricas de Avaliação do Nível de Severidade	119
4	Resultados	120
4.1	Avaliação em Nível de Pixel	120
4.2	Avaliação do Nível de Severidade	123
5	Discussão	129
6	Conclusão	130
7	Trabalhos Futuros	131
8	Anexo	131
8.1	Pré-Processamento das Imagens	131
8.2	Inferência e geração das máscaras previstas com o modelo treinado - Mask R-CNN	133
8.3	Inferência e geração das máscaras previstas com o modelo treinado - YOLOv8	134
8.4	Deteccão de contornos e cálculo da área da folha	135
8.5	Cálculo de Área de Lesão - Imagens de Referência	136
8.6	Cálculo de Área de Lesão - Imagens Previstas	137
8.7	Determinação da severidade de referência e prevista	138
	Referências	138
	 CAPÍTULO III	143
	FitoView: Integração de Redes Neurais Convolucionais e Dados Climáticos no Manejo da Cercosporiose em Pimenta Malagueta	143
1	Introdução	146
2	Estudo de caso: Mancha-de-cercóspora em pimenta malagueta	147
3	Materiais e Métodos	148
3.1	Aquisição de Dados Climáticos	148
3.2	Validação de Dados da API OpenMeteo	149
3.3	Desenvolvimento de Modelos CNN Customizados	149
3.3.1	Deteccão e Classificação de Doenças	149
3.3.2	Avaliação de Severidade de Doenças	151
3.4	Fluxo de Trabalho do Sistema e Lógica de Decisão para Mancha-de- Cercóspora em Pimenta Malagueta	151
3.4.1	Etapa 1: Configuração do Usuário e Seleção de Doença	152
3.4.2	Etapa 2: Avaliação Inicial e Decisão do Usuário	152

3.4.3	Etapa 3a: Manejo Preventivo/Monitoramento (Sem Sintomas Visíveis)	152
3.4.4	Etapa 3b: Manejo Corretivo Convencional/Alternativo (Sintomas Visíveis)	153
3.4.5	Condições de Pulverização	155
3.5	Arquitetura da Aplicação	156
3.5.1	Implantação e Infraestrutura do Sistema	157
3.5.2	Infraestrutura Backend: Serviço de Inferência de IA	157
3.5.3	Arquitetura Frontend: Aplicação Web Progressiva	158
3.5.4	Estimativa de Custos Operacionais e Financiamento	158
4	Resultados	160
4.1	Validação da API OpenMeteo	160
4.2	Treinamento e Desempenho do Modelo de Detecção de Doenças YOLOv8	163
4.2.1	Análise de Convergência do Treinamento	164
4.2.2	Desempenho do Modelo no Conjunto de Dados de Teste	165
4.3	Protótipo da Aplicação: Interface e Operação em Campo	167
4.3.1	Teste em Campo e Validação Prática	169
4.4	Estimativas de Custos Operacionais	170
5	Discussão	172
5.1	Desempenho e Confiabilidade da API OpenMeteo para Aplicações Agrícolas Locais	172
5.2	Desempenho do Modelo YOLOv8 e Relevância Clínica	172
5.3	O Protótipo no Contexto dos Ecossistemas Digitais Agrícolas Brasileiros	173
5.4	Inovações, Limitações Práticas e Trajetória Futura	174
6	Conclusão	175
	Referências	176
	CAPÍTULO IV	181
	Desafios e Oportunidades para a Implementação de Tecnologias da Agricultura 4.0 junto a Pequenos Agricultores: Uma Abordagem de Engajamento Comunitário e Transferência de Conhecimento no Município de Lagarto	181
1	Introdução	184
2	Metodologia	185
2.1	Abordagem Metodológica	185
2.2	Fase Look: Visita Inicial e Identificação do Problema	185
2.3	Fase Act: Desenvolvimento Técnico e Ações de Engajamento Comunitário	186
2.3.1	Desenvolvimento da Plataforma FitoView	186
2.3.2	Ações de Engajamento Comunitário	187
2.3.2.1	Apresentação no Movimento Camponês Livre (MCP)	187
2.3.2.2	Entrevista em Rádio Local	187

2.3.2.3	Desenvolvimento de Cartilha Educativa	188
2.3.2.4	Desenvolvimento de Vídeo Demonstrativo	191
2.4	Fase Think: Análise dos Dados e Identificação de Categorias	191
3	Resultados	192
3.1	Desafios Identificados para Adoção de Tecnologias	192
3.1.1	Limitações de Conectividade	192
3.1.2	Necessidade de Capacitação Digital	193
3.1.3	Barreiras Econômicas	193
3.2	Oportunidades Identificadas	193
3.2.1	Alta Penetração de Smartphones	193
3.2.2	Interesse Demonstrado pelos Agricultores	194
3.2.3	Potencial de Parcerias com Organizações Locais	194
3.2.4	Demanda por Ferramentas que Reduzam Uso de Agrotóxicos	194
4	Discussão	194
5	Conclusão	197
	Referências	198
8	CONCLUSÃO GERAL	199
9	ANEXOS	201
9.1	Laudo de Diagnóstico Fitossanitário	201

RESUMO GERAL

REDES NEURAIS CONVOLUCIONAIS E PREVISÃO CLIMÁTICA NO MONITORAMENTO E MANEJO DA CERCOSPORIOSE EM CULTURAS DE PIMENTA

Autor: Douglas Vieira Leite

Orientador: Prof. Dr. Gregorio Guirado Faccioli

Programa de Doutorado em Desenvolvimento e Meio Ambiente

São Cristóvão, 2026.

A cercosporiose, causada pelo fungo *Cercospora capsici*, constitui um importante desafio fitossanitário para o cultivo da pimenta malagueta (*Capsicum frutescens*), resultando em perdas de produtividade e no aumento do uso de defensivos agrícolas. Esta tese teve como objetivo geral promover a utilização de redes neurais convolucionais (CNNs) integradas a dados de previsão climática para a detecção automática, a quantificação da severidade e o apoio ao manejo sustentável da cercosporiose. A pesquisa foi desenvolvida majoritariamente no município de Lagarto, Sergipe (coordenadas: 10,91°S, 37,66°W), e estruturou-se em quatro estudos complementares, contemplando dimensões técnicas, tecnológicas e sociais. O primeiro estudo consistiu em uma revisão sistemática da literatura, na qual foram analisados 64 trabalhos que abordaram o uso de CNNs na avaliação automática da severidade de doenças em plantas. O segundo estudo dedicou-se ao desenvolvimento, comparação e validação de oito modelos customizados baseados nas arquiteturas Mask R-CNN e YOLOv8, utilizando um conjunto de dados original composto por 1.645 imagens de folhas e 6.282 lesões anotadas, coletadas em condições reais de campo. Esse conjunto de dados foi disponibilizado publicamente para a comunidade científica. Os modelos baseados em Mask R-CNN apresentaram melhor desempenho em métricas em nível de pixel, destacando-se o modelo *mask_rcnn_R101_FPN_3x*, que alcançou MIOU de 86,0% e F1-score de 92,4%. Por sua vez, na classificação dos níveis de severidade, os modelos YOLOv8 demonstraram desempenho superior, com o YOLOv8n-Seg atingindo precisão de 95,2% e F1-score de 95,1%. O terceiro estudo integrou os modelos de segmentação a dados climáticos obtidos via API em um sistema móvel de apoio à decisão denominado FitoView, implementado como uma aplicação web progressiva (PWA) na Google Cloud Platform. A validação da API OpenMeteo indicou correlações elevadas com dados do INMET para as variáveis de temperatura (coeficiente de correlação de Pearson r entre 0,90 e 0,97), umidade relativa (r entre 0,81 e 0,95) e radiação solar ($r > 0,90$) em quatro municípios do estado de Sergipe. O sistema combina a análise de imagens por CNNs com previsões

meteorológicas de 48 horas, gerando recomendações contextualizadas por meio de uma matriz de decisão que considera a severidade detectada, o risco climático e as condições adequadas para pulverização. O quarto estudo investigou os desafios e as oportunidades para a implementação de tecnologias da Agricultura 4.0 junto a agricultores familiares do município de Lagarto, utilizando abordagens participativas que incluíram a apresentação do sistema FitoView, entrevistas em rádio local e o desenvolvimento de material educativo. A metodologia adotada baseou-se em processos dialógicos de interlocução e divulgação, possibilitando a identificação de limitações estruturais, como restrições de conectividade e a necessidade de capacitação digital, bem como de oportunidades relevantes, com destaque para a ampla disseminação do uso de *smartphones*. Em síntese, os resultados dos quatro estudos demonstram que a integração entre inteligência artificial e dados climáticos pode atuar de forma efetiva como ferramenta de apoio ao controle de doenças, promovendo práticas de manejo mais sustentáveis e com potencial para reduzir o uso de defensivos agrícolas, especialmente quando desenvolvida em consonância com as realidades, necessidades e potencialidades da agricultura familiar local.

Palavras-chave: Aprendizado profundo, Visão computacional, Agricultura de precisão, *Cercospora capsici*, *Capsicum frutescens*.

Objetivos de Desenvolvimento Sustentável: #02 - Fome Zero e Agricultura Sustentável; #03 - Saúde e Bem-estar; #09 - Indústria, Inovação e Infraestrutura; #12 - Consumo e Produção Responsáveis.

GENERAL ABSTRACT

CONVOLUTIONAL NEURAL NETWORKS AND WEATHER FORECASTING FOR MONITORING AND MANAGEMENT OF CERCOSPORA LEAF SPOT IN PEPPER CROPS

Author: Douglas Vieira Leite

Advisor: Prof. Dr. Gregorio Guirado Faccioli

Doctoral Program in Development and Environment

São Cristóvão, 2026.

Cercospora leaf spot, caused by the fungus *Cercospora capsici*, represents a major phytosanitary challenge for the cultivation of malagueta pepper (*Capsicum frutescens*), leading to yield losses and increased use of chemical pesticides. This thesis aimed to promote the use of convolutional neural networks (CNNs) integrated with climate forecast data for the automatic detection, severity quantification, and support of sustainable management of Cercospora leaf spot. The research was conducted in the municipality of Lagarto, state of Sergipe, Brazil (coordinates: 10.91°S, 37.66°W), and was structured into four complementary studies encompassing technical, technological, and social dimensions. The first study consisted of a systematic literature review, analyzing 64 studies addressing the use of CNNs for automatic assessment of plant disease severity. The second study focused on the development, comparison, and validation of eight customized models based on the Mask R-CNN and YOLOv8 architectures, using an original dataset composed of 1,645 leaf images containing 6,282 annotated lesions collected under real field conditions. This dataset was made publicly available to the scientific community. Mask R-CNN-based models achieved superior performance in pixel-level metrics, with the *mask_rcnn_R101_FPN_3x* model reaching an MIoU of 86.0% and an F1-score of 92.4%. In contrast, YOLOv8 models outperformed in disease severity level classification, with the YOLOv8n-Seg model achieving a precision of 95.2% and an F1-score of 95.1%. The third study integrated the segmentation models with climate data obtained via API into a mobile decision support system named FitoView, implemented as a Progressive Web Application (PWA) on the Google Cloud Platform. Validation of the OpenMeteo API revealed high correlations with INMET data for temperature (Pearson correlation coefficient r between 0.90 and 0.97), relative humidity (r between 0.81 and 0.95), and solar radiation ($r > 0.90$) across four municipalities in the state of Sergipe. The system combines CNN-based image analysis with 48-hour weather forecasts, generating contextualized recommendations through a decision matrix that considers detected disease severity, climatic risk, and suitable spraying conditions. The

fourth study investigated challenges and opportunities for implementing Agriculture 4.0 technologies among family farmers in the municipality of Lagarto, using participatory approaches that included the presentation of the FitoView system, interviews on local radio, and the development of educational materials. The adopted methodology was based on dialogical processes of engagement and dissemination, enabling the identification of structural limitations—such as connectivity constraints and the need for digital skills training—as well as significant opportunities, particularly the widespread adoption of smartphones. In summary, the results of the four studies demonstrate that the integration of artificial intelligence and climate data can effectively support plant disease control and promote more sustainable management practices, with the potential to reduce pesticide use, especially when developed in alignment with the realities, needs, and capacities of local family farming systems.

Keywords: Deep learning, Computer vision, Precision agriculture, *Cercospora capsici*, *Capsicum frutescens*.

Sustainable Development Goals: #02 - Zero Hunger and Sustainable Agriculture; #03 - Good Health and Well-being; #09 - Industry, Innovation and Infrastructure; #12 - Responsible Consumption and Production.

LISTA DE SIGLAS

ACM (Association for Computing Machinery – Associação para Maquinaria de Computação)

API (Application Programming Interface – Interface de Programação de Aplicação)

APPIP (Associação dos Produtores do Perímetro Irrigado do Piauí)

CNN (Convolutional Neural Network – Rede Neural Convolucional)

COCO (Common Objects in Context – Objetos Comuns em Contexto)

CODERSE (Companhia de Desenvolvimento Regional de Sergipe)

DL (Deep Learning – Aprendizado Profundo)

EQM (Erro Quadrático Médio)

FCN (Fully Convolutional Network – Rede Totalmente Convolucional)

FPN (Feature Pyramid Network – Rede de Pirâmide de Características)

GPU (Graphics Processing Unit – Unidade de Processamento Gráfico)

IA (Inteligência Artificial)

IEEE (Institute of Electrical and Electronics Engineers – Instituto de Engenheiros Elétricos e Eletrônicos)

IFS (Instituto Federal de Sergipe)

INMET (Instituto Nacional de Meteorologia)

IoT (Internet of Things – Internet das Coisas)

IPT (Técnicas de Processamento de Imagens)

JCR (Journal Citation Reports – Relatórios de Citações de Periódicos)

M2M (Machine-to-Machine – Máquina-Máquina)

MAE (Mean Absolute Error – Erro Absoluto Médio)

Mask R-CNN (Mask Region-based Convolutional Neural Network – Rede Neural Convolucional Baseada em Região com Máscara)

MCL (Movimento Camponês Livre)

MCP (Movimento Camponês Popular)

MID (Manejo Integrado de Doenças)

MIoU (Mean Intersection over Union – Média da Intersecção sobre a União)

MIP (Manejo Integrado de Pragas)

ML (Machine Learning – Aprendizado de Máquina)

ODS (Objetivos de Desenvolvimento Sustentável)

ONU (Organização das Nações Unidas)

PLN (Processamento de Linguagem Natural)

PRODEMA (Programa de Doutorado em Desenvolvimento e Meio Ambiente)

PWA (Progressive Web Application – Aplicação Web Progressiva)

ResNet (Residual Network – Rede Residual)

RGB (Red, Green, Blue – Vermelho, Verde, Azul)

RMSE (Root Mean Square Error – Raiz do Erro Quadrático Médio)
ROI (Region of Interest – Região de Interesse)
RQ (Research Question – Questão de Pesquisa)
RPN (Region Proposal Network – Rede de Proposta de Região)
SDG (Sustainable Development Goals – Objetivos de Desenvolvimento Sustentável)
UFCG (Universidade Federal de Campina Grande)
UFLA (Universidade Federal de Lavras)
UFPB (Universidade Federal da Paraíba)
UFRN (Universidade Federal do Rio Grande do Norte)
UFS (Universidade Federal de Sergipe)
VGG (Visual Geometry Group – Grupo de Geometria Visual)
VIA (VGG Image Annotator – Anotador de Imagens VGG)
YOLO (You Only Look Once – Você Só Olha Uma Vez)

1 Introdução Geral

A crescente preocupação com os impactos ambientais das atividades humanas, especialmente na produção agrícola, tem impulsionado a busca por práticas mais sustentáveis. Dados recentes do Atlas do Uso de Agrotóxicos no Brasil (2024) indicam que o país segue entre os maiores consumidores desses produtos, registrando cerca de 720 mil toneladas em 2021 e aproximadamente 800 mil toneladas em 2022. Entre 2009 e 2022, o consumo nacional aumentou 161%. Esse cenário reforça a necessidade de estratégias que reduzam a dependência de defensivos químicos e promovam um manejo agrícola mais eficiente e ambientalmente seguro. Em paralelo, o Ministério da Agricultura e Pecuária (Mapa) registrou em 2025 a liberação de 912 novos agrotóxicos e defensivos biológicos, volume 37% superior ao de 2024 (663 produtos), impulsionado pela implementação da nova Lei dos Agrotóxicos (sancionada no final de 2023), que visou acelerar os processos de análise e registro.

Nesse contexto, a chamada quarta revolução tecnológica tem transformado profundamente os sistemas produtivos, incluindo a agricultura. A Agricultura 4.0 caracteriza-se pela incorporação de tecnologias digitais avançadas, como Internet das Coisas (IoT), inteligência artificial, *big data*, computação em nuvem e análise massiva de dados. Essas tecnologias possibilitam monitoramento em tempo real, automação de processos e tomada de decisões baseada em evidências, reduzindo custos, otimizando insumos e minimizando impactos ambientais. Entre essas inovações, destaca-se a aplicação de Redes Neurais Convolucionais (CNNs - Convolutional Neural Networks) para a detecção e avaliação automática da severidade de doenças em plantas.

A pesquisa foi desenvolvida no município de Lagarto/SE, cuja economia se estrutura principalmente na agricultura, pecuária e comércio. A atividade agrícola, em especial, ganha relevância graças ao Perímetro Irrigado Piauí, que, segundo a CODERSE (Companhia de Desenvolvimento Regional de Sergipe), é formado predominantemente por minifúndios — cerca de 95% das propriedades têm menos de 5 hectares. Com uma área total de 1.450 hectares, dos quais 703 irrigáveis, o perímetro atende aproximadamente 3.515 pessoas distribuídas em 421 propriedades. Nesse contexto produtivo, o cultivo de pimentas assume papel de destaque, impulsionado pela demanda crescente da indústria de molhos e conservas, sendo a pimenta malagueta (*Capsicum frutescens*) a principal cultura, com produção de 120 toneladas em 2021 (CODERSE, 2023).

Apesar do forte potencial agrícola, a adoção de tecnologias modernas na região ainda é limitada, e a incidência de pragas e doenças se destaca como um desafio expressivo. Entre elas, segundo técnicos da CODERSE, destaca-se a cercosporiose (*Cercospora capsici*), uma doença fúngica que provoca lesões foliares circulares, desfolhação e perdas de rendimento. Os técnicos relatam ainda que a doença tem ocasionado prejuízos recorrentes aos produtores,

levando ao uso periódico de fungicidas como tentativa de contenção, o que reforça a necessidade de estratégias de manejo mais eficientes e sustentáveis.

Diante desse cenário, a metodologia proposta neste trabalho busca detectar e mensurar automaticamente a severidade da doença por meio de imagens das folhas capturadas diretamente no campo, utilizando uma CNN treinada para segmentação e classificação da severidade. Essas informações serão integradas a dados climáticos atuais e de previsão, permitindo estimar condições favoráveis ao desenvolvimento da cercosporiose e apoiar recomendações de manejo. O algoritmo final será acessado por meio de um aplicativo móvel, facilitando sua utilização em tempo real pelo produtor. As decisões tomadas com base nesses dados podem gerar benefícios ambientais, econômicos e sociais: redução do uso de defensivos agrícolas e da contaminação ambiental, menor exposição dos trabalhadores a agentes tóxicos, economia de insumos e identificação precoce da doença, possibilitando um controle mais eficaz e direcionado.

A natureza desta pesquisa é interdisciplinar, integrando conhecimentos de diversas áreas. A pesquisa envolve a compreensão dos fenômenos físicos associados às condições climáticas e sua influência no desenvolvimento de doenças, fundamentos computacionais de inteligência artificial e visão computacional, além de dimensões sociais vinculadas à adoção de tecnologias por pequenos agricultores.

A hipótese central deste estudo é que a detecção e avaliação automática da severidade da cercosporiose, quando associadas a informações de previsão climática, podem aumentar a eficiência no controle da doença e fornecer subsídios relevantes aos pequenos agricultores, favorecendo tanto o combate ao patógeno quanto o manejo sustentável da cultura.

Com base nessa problemática e na hipótese formulada, o objetivo geral deste trabalho é promover a utilização de redes neurais convolucionais integradas a dados de previsão climática para a detecção automática, quantificação da severidade e apoio ao manejo sustentável da cercosporiose no cultivo da pimenta malagueta. Para alcançar esse objetivo, são definidos os seguintes objetivos específicos: (i) revisar sistematicamente os avanços no uso de redes neurais convolucionais para avaliação da severidade de doenças em plantas; (ii) desenvolver um modelo customizado baseado em CNN para detecção e cálculo automático da severidade de cercosporiose em folhas de pimenta malagueta; (iii) integrar a detecção automatizada aos dados climáticos locais e desenvolver um protótipo de aplicativo móvel funcional que ofereça informações relevantes ao manejo da cultura; e (iv) identificar desafios e oportunidades para a implementação de tecnologias da Agricultura 4.0 junto aos pequenos agricultores da região estudada.

Esta tese é organizada no formato de artigos complementares, distribuídos em oito seções: 1. Introdução Geral; 2. Fundamentação Teórica; 3. Materiais e Métodos; 4. Capítulo I (Artigo I: Revisão Sistemática sobre CNNs para Avaliação de Severidade de Doenças em Plantas); 5. Capítulo II (Artigo II: Modelos de Aprendizado Profundo para Detecção e Avaliação de Severidade da Mancha de Cercospora (*Cercospora capsici*) em

Pimentas sob Condições Naturais); 6. Capítulo III (Artigo III: FitoView - Integração de Redes Neurais Convolucionais e Dados Climáticos no Manejo da Cercosporiose); 7. Capítulo IV (Artigo IV: Desafios e Oportunidades para a Implementação de Tecnologias da Agricultura 4.0 junto a Pequenos Agricultores); e 8. Conclusão Geral. Cada artigo está vinculado a um dos objetivos específicos estabelecidos. Parte dos resultados, referentes aos capítulos I e II, já foi publicada em dois artigos em revistas internacionais Q1 nas categorias 'Agriculture, Multidisciplinary' e 'Plant Sciences', com JCR 2024 de 5,7 e 4,1, respectivamente..

2 Fundamentação Teórica

2.1 Desenvolvimento Sustentável e Agricultura

O quadro socioambiental que caracteriza as sociedades contemporâneas revela que o impacto dos humanos sobre o meio ambiente está se tornando cada vez mais complexo, tanto em termos quantitativos quanto qualitativos. O conceito de desenvolvimento sustentável surge para enfrentar a crise ecológica, sendo que, em seu início histórico, pelo menos duas correntes alimentaram esse processo. A primeira, mais radical, refletida no trabalho intitulado "*Limites do Crescimento*", publicado em 1972, propunha, de forma catastrofista, que para se alcançar a estabilidade econômica e ecológica, teria que se congelar o crescimento da população global e do capital industrial (Meadows; Randers, 1972). A segunda vertente está relacionada com a crítica ambientalista ao modo de vida contemporâneo, que se difundiu a partir da Conferência de Estocolmo, realizada em 1972, quando a questão ambiental ganhou visibilidade pública através da Declaração resultante desse evento (Declaration, 1972). Assim, o que se observa é que a ideia ou enfoque do desenvolvimento sustentável adquire relevância num curto espaço de tempo, assumindo um caráter diretivo nos debates sobre os rumos do desenvolvimento (Jacobi, 1999).

O conceito de desenvolvimento sustentável engloba um conjunto de ideias e abordagens que visam garantir o uso responsável e equilibrado dos recursos naturais, a fim de suprir as necessidades da humanidade. Esse termo foi introduzido em 1987 no Relatório *Brundtland*, publicado pela Organização das Nações Unidas, que definiu o desenvolvimento sustentável como aquele que "satisfaz as necessidades do presente sem comprometer a capacidade das gerações futuras satisfazerem as suas próprias necessidades" (Wced, 1987). Este conceito transcende a dimensão puramente econômica, incorporando aspectos sociais, ambientais e culturais que devem ser equilibrados para garantir a sustentabilidade dos sistemas produtivos (Oliveira Ribeiro *et al.*, 2022). A sustentabilidade, portanto, não pode ser reduzida a uma dimensão única, mas requer uma abordagem integrada que considere simultaneamente os pilares econômico, social e ambiental (Elkington; Rowlands, 1999).

Ao longo do tempo o próprio conceito de desenvolvimento foi se modificando, tornando-se não somente uma função direta da economia, mas sobretudo uma questão multifatorial. Ainda segundo Oliveira Ribeiro *et al.* (2022), o desenvolvimento deve ser encarado como um processo complexo de mudanças e transformações de ordem econômica, política e, principalmente, humana e social. Nesse contexto, as revoluções tecnológicas que em um primeiro momento só visavam o desenvolvimento econômico e por consequência severos danos ambientais vêm se modificando e trabalhando para uma nova perspectiva a favor da sustentabilidade. A transição para sistemas agrícolas mais sustentáveis requer não apenas inovações tecnológicas, mas também mudanças institucionais, políticas e comportamentais

que promovam a adoção de práticas ambientalmente responsáveis (Pretty, 2008).

A agricultura sustentável pode ser definida como um sistema de produção que mantém ou melhora a qualidade ambiental e os recursos naturais dos quais a agricultura depende, fornece necessidades humanas básicas de alimentos e fibras, é economicamente viável e melhora a qualidade de vida dos agricultores e da sociedade como um todo (Feenstra; Campbell; Chaney, 1997). Esta definição enfatiza a necessidade de equilibrar múltiplos objetivos, reconhecendo que a sustentabilidade agrícola não é um estado final, mas um processo contínuo de adaptação e melhoria (Reganold; Wachter, 2016).

Os sistemas agrícolas convencionais frequentemente dependem de insumos externos, incluindo fertilizantes sintéticos e agrotóxicos, que podem gerar externalidades ambientais significativas quando utilizados de forma intensiva (Damalas; Eleftherohorinos, 2011). A contaminação de solos, águas superficiais e subterrâneas por resíduos de pesticidas representa um desafio ambiental de escala global, com impactos que transcendem os limites das propriedades agrícolas e afetam ecossistemas adjacentes (Carneiro *et al.*, 2017). Além dos riscos ambientais, a exposição ocupacional e alimentar a agrotóxicos está associada a diversos problemas de saúde humana, incluindo distúrbios neurológicos, endócrinos e maior risco de desenvolvimento de certos tipos de câncer (Damalas; Eleftherohorinos, 2011). A perda de biodiversidade, especialmente de polinizadores e organismos benéficos do solo, é outra consequência preocupante do uso intensivo de pesticidas (Lamichhane *et al.*, 2016). Diante desses desafios, o manejo integrado de pragas e doenças (MIP/MID) emerge como uma abordagem estratégica que combina múltiplas táticas de controle, priorizando métodos não-químicos e utilizando agrotóxicos apenas quando necessário e de forma criteriosa (Lamichhane *et al.*, 2016). Tecnologias que permitem monitoramento preciso e detecção precoce de problemas fitossanitários são fundamentais para viabilizar essa abordagem, fornecendo informações que permitem intervenções mais precisas e reduzidas (Thenkabail; Lyon; Huete, 2018).

No contexto da Agenda 2030, a questão da sustentabilidade na agricultura assume papel central na consecução dos Objetivos de Desenvolvimento Sustentável (ODS). A Figura 1 apresenta os 17 ODS estabelecidos pela Organização das Nações Unidas, demonstrando a interconexão entre diferentes dimensões do desenvolvimento sustentável. Dentre esses objetivos, destacam-se particularmente o ODS 2 (Fome Zero e Agricultura Sustentável) e o ODS 12 (Consumo e Produção Responsáveis), que estabelecem uma relação direta e fundamental com as práticas agrícolas (United Nations, 2015).

O ODS 2 visa acabar com a fome, alcançar a segurança alimentar e melhorar a nutrição, promovendo a agricultura sustentável como estratégia central para garantir sistemas alimentares resilientes e produtivos. Este objetivo reconhece que a agricultura sustentável não apenas produz alimentos, mas também preserva os recursos naturais, protege a biodiversidade e fortalece a capacidade de adaptação às mudanças climáticas (United Nations, 2015). O ODS 12, por sua vez, busca garantir padrões de consumo e

produção sustentáveis, enfatizando a necessidade de reduzir o desperdício de alimentos, otimizar o uso de recursos naturais e minimizar os impactos ambientais das atividades produtivas, incluindo a redução do uso de agrotóxicos e a promoção de práticas agrícolas que respeitem os limites dos ecossistemas (United Nations, 2015).

A agricultura sustentável contribui ainda para o cumprimento de outros ODS, incluindo o ODS 6 (Água Potável e Saneamento), através da gestão eficiente dos recursos hídricos; o ODS 13 (Ação Contra a Mudança Global do Clima), por meio de práticas que reduzem emissões de gases de efeito estufa e aumentam a resiliência climática; e o ODS 15 (Vida Terrestre), através da conservação da biodiversidade e do uso sustentável dos ecossistemas terrestres (Liu; Zhou; Wu, 2020). Esta interconexão evidencia que o desenvolvimento de tecnologias sustentáveis para o manejo de doenças em cultivos agrícolas, como proposto neste trabalho, alinha-se diretamente com os objetivos da Agenda 2030, especialmente com os ODS 2 e 12, ao promover práticas agrícolas mais eficientes, reduzir o uso de insumos químicos e contribuir para sistemas alimentares mais sustentáveis.

Figura 1 – Os 17 Objetivos de Desenvolvimento Sustentável (ODS) da Agenda 2030 da Organização das Nações Unidas.



Fonte: Organização das Nações Unidas (2015).

2.2 Agricultura 4.0 e Tecnologias Digitais

A quarta revolução tecnológica, também conhecida como Indústria 4.0, traz à tona novas perspectivas para o uso sustentável das inovações. Esta revolução é caracterizada pela convergência de tecnologias digitais, físicas e biológicas, criando sistemas ciber-físicos que transformam fundamentalmente os processos produtivos (Schwab, 2017). Essa revolução também é refletida na chamada agricultura 4.0, que representa a aplicação dessas tecnologias avançadas no setor agrícola. A agricultura 4.0 é responsável pelo

uso de novas tecnologias distintas, que através do monitoramento, uso de sensores e tecnologia IoT (internet das coisas) já vem provocando transformações consideráveis em sua aplicação (Weersink *et al.*, 2021). É interessante notar que essa revolução tecnológica possibilitou avanços não somente aos setores industriais, mas também em outros setores, como na agricultura, onde a digitalização está criando novas oportunidades para aumentar a eficiência e sustentabilidade (Aqeel-Ur-Rehman; Shaikh, 2009).

A Agricultura 4.0 incorpora avançadas tecnologias computacionais como redes de sensores, comunicação Máquina-Máquina (M2M), conectividade entre dispositivos móveis, computação em nuvem e soluções analíticas para lidar com grandes volumes de dados (Rose *et al.*, 2021). Essas tecnologias são aplicadas para construir sistemas de apoio à tomada de decisões na gestão agrícola, permitindo monitoramento em tempo real, análise preditiva e automação de processos (Zhai *et al.*, 2020). Além disso, a Agricultura 4.0 contribui para aumentar a produtividade, otimizar o uso de insumos, melhorar a qualidade do trabalho e a segurança dos trabalhadores, além de reduzir os impactos ambientais (Massruhá; Leite, 2017). A integração de tecnologias como inteligência artificial, aprendizado de máquina, visão computacional e análise de big data está revolucionando a forma como as decisões agrícolas são tomadas, permitindo uma abordagem mais precisa e baseada em dados (Liakos *et al.*, 2018).

A computação em nuvem oferece a infraestrutura necessária para armazenar, processar e analisar os grandes volumes de dados gerados por sensores, dispositivos móveis e IoT (Wang *et al.*, 2010). Esta capacidade é essencial para aplicações de big data e aprendizado de máquina, que requerem recursos computacionais significativos (Kamilaris *et al.*, 2018). A análise de dados agrícolas em larga escala permite identificar padrões, prever eventos e otimizar práticas de manejo de forma que não seria possível com métodos tradicionais (Weersink *et al.*, 2021).

A implementação da Agricultura 4.0 apresenta desafios relacionados à acessibilidade e adoção, especialmente considerando a diversidade de perfis de produtores rurais. Embora essas tecnologias ofereçam benefícios significativos, sua adoção não é uniforme entre diferentes tipos de propriedades agrícolas. A questão da acessibilidade tecnológica e dos desafios específicos enfrentados por diferentes segmentos do setor agrícola, particularmente a agricultura familiar, será abordada em detalhes na seção 2.6 deste capítulo.

2.3 Doenças de Plantas e Avaliação de Severidade

As doenças de plantas representam uma das principais causas de perdas na produção agrícola mundial, resultando em reduções significativas de produtividade e qualidade dos produtos agrícolas. Estima-se que doenças, pragas e ervas daninhas causem perdas médias de 21,5% na produção de cultivos alimentares globalmente, com variações significativas entre diferentes cultivos e regiões (Savary *et al.*, 2019). No contexto brasileiro, as doenças

fúngicas, bacterianas e virais representam desafios constantes para a produção agrícola, exigindo estratégias eficazes de monitoramento e manejo (Agrios, 2005).

Dentro do escopo de novas tecnologias aplicadas na agricultura, algumas soluções lidam com a avaliação da saúde do cultivo. Segundo Thenkabail, Lyon e Huete (2018), essa prática contribui no uso eficiente de recursos, permitindo a detecção precoce de estresses, doenças, pragas e deficiências nutricionais nas plantas. Com essa informação, é possível realizar intervenções pontuais e direcionadas, otimizando o uso de recursos como a água, fertilizantes e pesticidas. Isso reduz o desperdício de insumos agrícolas e contribui para a sustentabilidade ambiental. Ao identificar áreas com problemas específicos, é possível implementar práticas agrícolas de precisão, como a aplicação localizada de insumos, evitando a dispersão desnecessária de produtos químicos no ambiente e conservando a biodiversidade (Lamichhane *et al.*, 2016). Uma abordagem bem difundida para quantificar a intensidade de uma doença é estimando a sua severidade, definida aqui como a quantidade de área lesionada em relação à quantidade de área suscetíveis disponíveis (Nutter Jr.; Teng; Shokes, 1991).

A severidade da doença é um parâmetro quantitativo fundamental em fitopatologia, representando a proporção de tecido vegetal afetado por uma doença em relação ao tecido total disponível. Este parâmetro difere da incidência, que mede a proporção de plantas ou órgãos afetados, independentemente da extensão do dano (Madden, 2007). A severidade é particularmente importante porque está diretamente relacionada ao impacto da doença na produtividade e qualidade da cultura, permitindo estimativas mais precisas de perdas e orientando decisões de manejo (Nutter Jr.; Teng; Shokes, 1991).

Existem diferentes métodos utilizados para determinar a severidade, incluindo escalas diagramáticas, escalas descritivas e a análise de imagens computacionais (Bock *et al.*, 2010). As escalas diagramáticas consistem em ilustrações padronizadas que representam diferentes níveis de severidade, facilitando a comparação visual e reduzindo a variabilidade entre avaliadores (Del Ponte, 2005). As escalas descritivas utilizam descrições textuais dos níveis de severidade, enquanto métodos baseados em análise de imagens digitais oferecem maior precisão e objetividade (Bock *et al.*, 2010).

Além do problema da repetibilidade, a determinação da severidade através de análise visual é demorada e propensa a erros, pois esse método de quantificação é subjetivo, exigindo grande conhecimento sobre a doença estudada. O olho humano tem capacidade limitada para interpretar pequenas diferenças sendo muito difícil para a determinação visual precisa. O que geralmente ocorre é a subjetividade da percepção da quantidade da doença pelo avaliador, com variações entre diferentes avaliadores, levando a uma superestimação ou subestimativa da doença (Madden, 2007). Estudos demonstram que mesmo avaliadores experientes podem apresentar variações significativas em suas estimativas, com coeficientes de variação frequentemente superiores a 20% (Bock *et al.*, 2010). Esta variabilidade pode comprometer a confiabilidade dos dados coletados e afetar a eficácia das estratégias de

manejo baseadas nessas avaliações (Nutter Jr.; Teng; Shokes, 1991).

A análise de imagens digitais oferece uma alternativa mais objetiva e precisa para a avaliação de severidade, reduzindo a variabilidade entre avaliadores e aumentando a reprodutibilidade dos resultados (Bock *et al.*, 2010). Métodos baseados em processamento de imagens podem detectar e quantificar lesões com maior precisão do que métodos visuais, especialmente em casos de baixa severidade ou quando múltiplas doenças estão presentes simultaneamente (Barbedo, 2019). A automação deste processo através de técnicas de visão computacional e aprendizado de máquina representa um avanço significativo, permitindo avaliações rápidas, precisas e escaláveis (Shi *et al.*, 2023).

2.4 Redes Neurais Convolucionais e Visão Computacional

A visão computacional é um campo interdisciplinar que visa desenvolver métodos e técnicas para extrair informações significativas de imagens digitais (Stockman; Shapiro, 2001). No contexto agrícola, a visão computacional tem sido amplamente aplicada para tarefas como detecção de doenças, identificação de pragas, avaliação de maturidade de frutos, monitoramento de crescimento de plantas e quantificação de estresses abióticos (Liakos *et al.*, 2018). Os algoritmos da visão computacional têm a capacidade de extrair informações relevantes a partir de imagens capturadas por câmeras fotográficas, vídeos, sensores, entre outros dispositivos, para automatizar a tomada de decisão em um sistema (Stockman; Shapiro, 2001).


Com o desenvolvimento tecnológico, métodos automáticos para a detecção de lesões em plantas vêm sendo estudados. Ferramentas para reconhecimento automático de doenças de plantas utilizando Inteligência Artificial (IA) têm o potencial de se tornar uma valiosa fonte de informação para auxiliar na tomada de decisão em cultivos (Barbedo; Garcia, 2013). Entre as abordagens mais recentes, os modelos de aprendizagem profunda (*deep learning*), com destaque para as CNNs, têm se consolidado como a escolha preferida para superar muitos desses desafios (Barbedo, 2018). A combinação dos recursos da visão computacional com o poder da inteligência artificial na aprendizagem profunda podem gerar ferramentas práticas poderosas para aplicação na agricultura e ajudar em projetos de tecnologias sustentáveis (Liakos *et al.*, 2018).

Ainda existe um amplo campo de estudo nesta temática e diversos desafios a superar, como por exemplo a escassez de amostras de imagens de lesões em plantas e a dificuldade em se gerar bancos de dados personalizados robustos para treinamento, a dificuldade de leitura de imagens com grande variação de luminosidade e a segmentação dessas folhas em ambientes complexos (Liu; Wang, 2021). Outros desafios incluem a necessidade de modelos que funcionem bem em diferentes variações sazonais, diferentes estágios de desenvolvimento da doença e a presença de múltiplas doenças simultaneamente (Too *et al.*, 2019).

As CNNs são arquiteturas de aprendizado profundo projetadas especificamente para

processar dados estruturados em matrizes, especialmente para tarefas de visão computacional (LeCun *et al.*, 2015). As CNNs consistem em várias camadas que aprendem automaticamente características hierárquicas das imagens de entrada, incluindo camadas convolucionais, de pooling e totalmente conectadas. A principal vantagem das CNNs sobre métodos tradicionais de visão computacional é sua capacidade de aprender representações de características automaticamente a partir dos dados, sem necessidade de engenharia manual de características (Goodfellow *et al.*, 2016). A estrutura geral de uma CNN é ilustrada na Figura 2.

Figura 2 – Estrutura geral de uma Rede Neural Convolucional (CNN) mostrando as principais camadas: entrada, convolucional, pooling, totalmente conectada e saída.



Fonte: (Ratan, 2020).

O processo de aprendizado em CNNs começa com a camada de entrada, que representa uma imagem como um array multidimensional, tipicamente com dimensões altura $\times$ largura $\times$ canais (por exemplo, RGB com 3 canais) (Goodfellow *et al.*, 2016). A operação de convolução envolve deslizar pequenas matrizes (kernels ou filtros) sobre a imagem de entrada, realizando multiplicação elemento por elemento e gerando mapas de características que destacam características locais específicas, como bordas ou texturas (LeCun *et al.*, 1998). Cada filtro convolucional aprende a detectar diferentes padrões espaciais, criando uma representação hierárquica onde camadas iniciais detectam características de baixo nível (bordas, texturas) e camadas mais profundas detectam características de alto nível (formas, objetos) (Zeiler *et al.*, 2014).

Após a convolução, os mapas de características são passados por funções de ativação não lineares, tipicamente a Unidade Linear Retificada (ReLU), que introduz não linearidade no modelo, permitindo que ele capture padrões complexos nos dados (Nair *et al.*, 2010).

A função ReLU é definida como $f(x) = \max(0, x)$, sendo computacionalmente eficiente e ajudando a mitigar o problema de gradientes que desaparecem durante o treinamento (Goodfellow *et al.*, 2016).

Camadas de pooling são aplicadas para reduzir as dimensões espaciais dos mapas de características, diminuindo a complexidade computacional e tornando a rede mais robusta a variações na entrada (Goodfellow *et al.*, 2016). O tipo mais comum é o max pooling, que seleciona o valor máximo dentro de uma pequena região do mapa de características, preservando as características mais proeminentes enquanto reduz a resolução espacial (LeCun *et al.*, 1998). Após várias camadas de convolução e pooling, os mapas de características de alto nível são achatados e alimentados em camadas totalmente conectadas, que realizam as tarefas finais de classificação ou regressão (Goodfellow *et al.*, 2016).

Ao longo dos anos, os modelos baseados em CNNs evoluíram significativamente. Marcos notáveis incluem o desenvolvimento da arquitetura LeNet-5 para reconhecimento de dígitos manuscritos (LeCun *et al.*, 1998) e o trabalho pioneiro de Krizhevsky *et al.* (2012) que demonstrou o potencial das CNNs para aprender características complexas e hierárquicas, vencendo o desafio ImageNet e iniciando a era moderna do aprendizado profundo (Krizhevsky *et al.*, 2012). Modelos subsequentes como VGGNet, GoogLeNet, ResNet e DenseNet avançaram continuamente o campo, introduzindo conceitos como blocos residuais, conexões densas e arquiteturas mais profundas (Simonyan *et al.*, 2014; Szegedy *et al.*, 2015; He; Zhang *et al.*, 2016; Huang *et al.*, 2017).

2.4.1 Arquiteturas para Segmentação de Instâncias

A segmentação de instâncias é uma tarefa de visão computacional que combina detecção de objetos e segmentação semântica, com o objetivo de detectar, classificar e delimitar instâncias individuais de objetos em uma imagem (He; Gkioxari *et al.*, 2017). Esta técnica tem surgido como uma ferramenta crítica para a agricultura de precisão, permitindo a detecção e localização precisa de lesões de doenças em plantas, quantificação de severidade e análise de padrões espaciais de distribuição (Shi *et al.*, 2023). Diferentemente da segmentação semântica, que classifica cada pixel sem distinguir instâncias diferentes, a segmentação de instâncias identifica e separa cada objeto individual, mesmo quando múltiplos objetos da mesma classe estão presentes na mesma imagem (Goodfellow *et al.*, 2016). A Figura 3 ilustra a diferença entre classificação de imagens, detecção de objetos e segmentação de instâncias, destacando como esta última técnica identifica precisamente quais pixels pertencem a cada objeto individual na imagem.

Figura 3 – Comparação entre classificação de imagens, detecção de objetos e segmentação de instâncias. A segmentação de instâncias identifica precisamente quais pixels pertencem a cada objeto individual na imagem.



Fonte: (SuperAnnotate, 2023).

O desenvolvimento de algoritmos de segmentação de instâncias evoluiu significativamente ao longo dos anos. Inicialmente, métodos baseados em técnicas tradicionais de processamento de imagens, como watershed, clustering e métodos baseados em contornos, eram utilizados para segmentação (Long *et al.*, 2015). Com o advento do aprendizado profundo, arquiteturas baseadas em CNNs revolucionaram o campo. A Fully Convolutional Network (FCN), desenvolvida em 2015, foi um marco importante, sendo a primeira arquitetura totalmente convolucional para segmentação semântica (Long *et al.*, 2015). Arquiteturas subsequentes como SegNet, U-Net e DeepLab avançaram significativamente a precisão da segmentação semântica (Badrinarayanan *et al.*, 2017; Ronneberger *et al.*, 2015; Chen *et al.*, 2017).

A evolução para segmentação de instâncias exigiu a combinação de técnicas de detecção de objetos com segmentação. Arquiteturas de detecção de objetos como R-CNN, Fast R-CNN e Faster R-CNN estabeleceram a base para abordagens de duas etapas, onde primeiro objetos são detectados e depois segmentados (Girshick *et al.*, 2014; Girshick, 2015; Ren *et al.*, 2015). Paralelamente, arquiteturas de uma etapa como YOLO e SSD foram desenvolvidas para oferecer maior velocidade de processamento, sacrificando parcialmente a precisão em favor da eficiência (Redmon *et al.*, 2016; Liu; Anguelov *et al.*, 2016).

Diversas arquiteturas têm sido desenvolvidas para segmentação de instâncias, cada uma com características e trade-offs específicos. Além do Mask R-CNN e YOLO, outras arquiteturas incluem YOLACT (You Only Look At CoefficientTs), que combina detecção de objetos com geração de máscaras em uma única passagem, oferecendo uma alternativa de uma etapa com boa eficiência (Bolya *et al.*, 2019). Arquiteturas baseadas em Transformers também têm emergido como uma abordagem promissora. Os Transformers são modelos que utilizam mecanismos de auto-atenção para capturar relações entre diferentes partes da entrada, originalmente aplicados em processamento de linguagem natural e posteriormente

adaptados para visão computacional, permitindo segmentação com base em dependências de longo alcance na imagem. Essas diferentes abordagens refletem a evolução contínua do campo, com cada arquitetura oferecendo soluções específicas para os desafios da segmentação de instâncias (Goodfellow *et al.*, 2016).

Entre as arquiteturas disponíveis, duas se destacam particularmente para aplicações em agricultura de precisão: Mask R-CNN e YOLO. O Mask R-CNN, desenvolvido por He, Gkioxari *et al.* (2017), representa uma evolução do Faster R-CNN, adicionando uma ramificação paralela para geração de máscaras de segmentação. Esta arquitetura de duas etapas primeiro utiliza uma Region Proposal Network (RPN) para gerar propostas de regiões de interesse, que são então classificadas e refinadas (Ren *et al.*, 2015). Em seguida, uma rede de cabeça de máscara gera máscaras binárias de alta resolução para cada instância detectada. O Mask R-CNN demonstra excelente precisão, especialmente em tarefas que requerem segmentação pixel a pixel precisa, sendo amplamente utilizado em aplicações onde a qualidade da segmentação é prioritária sobre a velocidade de processamento (Shi *et al.*, 2023).

O YOLO (You Only Look Once), por sua vez, representa uma abordagem fundamentalmente diferente, priorizando velocidade de inferência. Desenvolvido originalmente para detecção de objetos, o YOLO processa a imagem inteira em uma única passagem pela rede, dividindo-a em uma grade e predizendo caixas delimitadoras e classes simultaneamente (Redmon *et al.*, 2016). Versões subsequentes, como YOLOv4, YOLOv5 e YOLOv8, incorporaram capacidades de segmentação de instâncias, mantendo a arquitetura de uma etapa que caracteriza a família YOLO (Bochkovskiy *et al.*, 2020; Jocher *et al.*, 2023). O YOLOv8, em particular, oferece suporte nativo para segmentação de instâncias através de sua arquitetura unificada, permitindo detecção, classificação e segmentação em uma única inferência (Jocher *et al.*, 2023).

2.5 Previsão Meteorológica e Manejo de Doenças

Um outro fator determinante na disseminação e no controle de doenças em um cultivo é o clima. As condições meteorológicas influenciam diretamente o ciclo de vida dos patógenos, a suscetibilidade das plantas hospedeiras e a eficácia dos tratamentos aplicados (Agrios, 2005). Variáveis climáticas como temperatura, umidade relativa do ar, precipitação, duração do período de molhamento foliar e radiação solar são fatores críticos que determinam a ocorrência, desenvolvimento e severidade de doenças em plantas (Del Ponte, 2005). A informação meteorológica pode fornecer aos produtores agrícolas informações importantes sobre as condições climáticas favoráveis ao desenvolvimento de doenças, permitindo que medidas preventivas sejam tomadas antecipadamente (Scolin, 2023).

Modelos epidemiológicos baseados em condições climáticas têm sido desenvolvidos para prever o risco de ocorrência de doenças em diferentes cultivos (Del Ponte, 2005). Estes

modelos utilizam dados meteorológicos históricos e em tempo real para calcular índices de risco, auxiliando na tomada de decisões sobre quando aplicar tratamentos preventivos ou curativos (Scolin, 2023). A integração de modelos epidemiológicos com sistemas de alerta fitossanitário tem demonstrado eficácia na redução do uso de agrotóxicos, aplicando-os apenas quando as condições climáticas indicam alto risco de desenvolvimento da doença (Del Ponte, 2005).

Ter acesso à dados climáticos contínuos locais utilizando estações meteorológicas pode ser custoso, especialmente para pequenos agricultores (Araújo *et al.*, 2025). Em certos casos pode-se fazer uso de novas estratégias de integração automática de dados disponibilizados na internet. O consumo automático de dados pode ser viabilizado por meio de uma interface de programação de aplicações, mais conhecida no termo em inglês *Application Programming Interface* (API) (Zippenfenig, 2023). Esses dados podem ser processados por algoritmos e utilizados em aplicações operadas por smartphones, por exemplo, e assim gerar informações vitais ao manejo da cultura de forma menos dispendiosa. APIs meteorológicas como OpenMeteo, WeatherAPI e outras oferecem acesso gratuito ou de baixo custo a dados meteorológicos históricos, em tempo real e de previsão, com resolução espacial adequada para aplicações agrícolas (Zippenfenig, 2023).

A validação de dados meteorológicos obtidos de fontes alternativas, como reanálises e APIs, é essencial para garantir a confiabilidade das informações utilizadas em sistemas de apoio à decisão (Araújo *et al.*, 2025). Dessa forma, a coleta de dados meteorológicos pode ajudar na identificação de condições climáticas ideais para o surgimento de patógenos e no planejamento de ações de prevenção adequadas e menos agressivas (Santos *et al.*, 2013). Os dados climáticos de previsão também são importantes na prevenção e controle de doenças em cultivos. Elas podem ajudar os produtores agrícolas a antecipar a ocorrência de condições climáticas adversas, como altas temperaturas, umidade elevada, períodos prolongados de seca ou chuvas intensas, que podem favorecer o aparecimento de doenças em plantações (Agrios, 2005). A previsão meteorológica de curto prazo (24-72 horas) é particularmente valiosa para planejar aplicações de fungicidas, considerando não apenas o risco de desenvolvimento da doença, mas também as condições ideais para aplicação, como ausência de vento forte e chuva iminente (Santos *et al.*, 2013).

A integração de dados meteorológicos com sistemas de detecção de doenças baseados em inteligência artificial permite criar matrizes de decisão que consideram tanto o estado atual da doença quanto as condições climáticas futuras (Scolin, 2023). Esta abordagem integrada permite gerar recomendações mais precisas e contextualizadas, otimizando o momento e a necessidade de intervenções fitossanitárias (Del Ponte, 2005).

2.6 Agricultura Familiar e Acessibilidade Tecnológica

A agricultura familiar desempenha papel fundamental no abastecimento alimentar do Brasil, sendo responsável por 77% dos estabelecimentos agrícolas e empregando 67% da força de trabalho agropecuária (IBGE, 2019). Além disso, a agricultura familiar é responsável por aproximadamente 38% do valor bruto da produção agropecuária nacional e por mais de 50% dos alimentos consumidos no país, incluindo 70% do feijão, 34% do arroz, 87% da mandioca e 60% da produção de leite (IBGE, 2019). Esta importância econômica e social torna essencial o desenvolvimento de tecnologias acessíveis que possam apoiar os pequenos agricultores em suas atividades produtivas (Proença *et al.*, 2015).

No entanto, os pequenos agricultores enfrentam desafios significativos para a adoção de tecnologias inovadoras. As principais barreiras identificadas incluem: (i) falta de conectividade confiável à internet nas propriedades rurais; (ii) falta de capacitação para lidar com tecnologias digitais; (iii) custos elevados de implementação; (iv) existência de soluções isoladas que não se integram; e (v) falta de garantias de retorno sobre o investimento tecnológico (Barrett *et al.*, 2021). A exclusão digital rural é um problema estrutural que limita o acesso dos pequenos agricultores a informações, mercados e serviços digitais (Proença *et al.*, 2015). Além disso, muitas tecnologias agrícolas digitais são desenvolvidas principalmente para grandes propriedades, não considerando as necessidades, recursos e limitações específicas dos pequenos agricultores (Baumüller, 2018).

No entanto, estudos recentes demonstram que, apesar das dificuldades, há potencial significativo para adoção de tecnologias móveis. Pesquisas com agricultores familiares indicam que praticamente todos possuem smartphones e já fazem uso de redes sociais, e cerca de 70% acessam a internet via dados móveis quando não há disponibilidade de rede wi-fi (Barrett *et al.*, 2021). A penetração de smartphones em áreas rurais tem crescido significativamente, criando oportunidades para o desenvolvimento de soluções baseadas em dispositivos móveis (Baumüller, 2018). Essas descobertas ressaltam a necessidade de desenvolver soluções tecnológicas que aproveitem a infraestrutura já existente (smartphones e conectividade móvel) e sejam projetadas para serem intuitivas e acessíveis (Rogers, 2003).

A teoria da difusão de inovações de Rogers fornece um direcionamento para entender os fatores que influenciam a adoção de tecnologias por agricultores (Rogers, 2003). Segundo esta teoria, a adoção de uma inovação depende de características como vantagem relativa, compatibilidade com valores e necessidades existentes, complexidade percebida, possibilidade de experimentação e observabilidade dos resultados (Rogers, 2003). Para tecnologias agrícolas digitais, a simplicidade de uso, o baixo custo, a compatibilidade com dispositivos existentes e a demonstração clara de benefícios são fatores críticos para a adoção por pequenos agricultores (Barrett *et al.*, 2021).

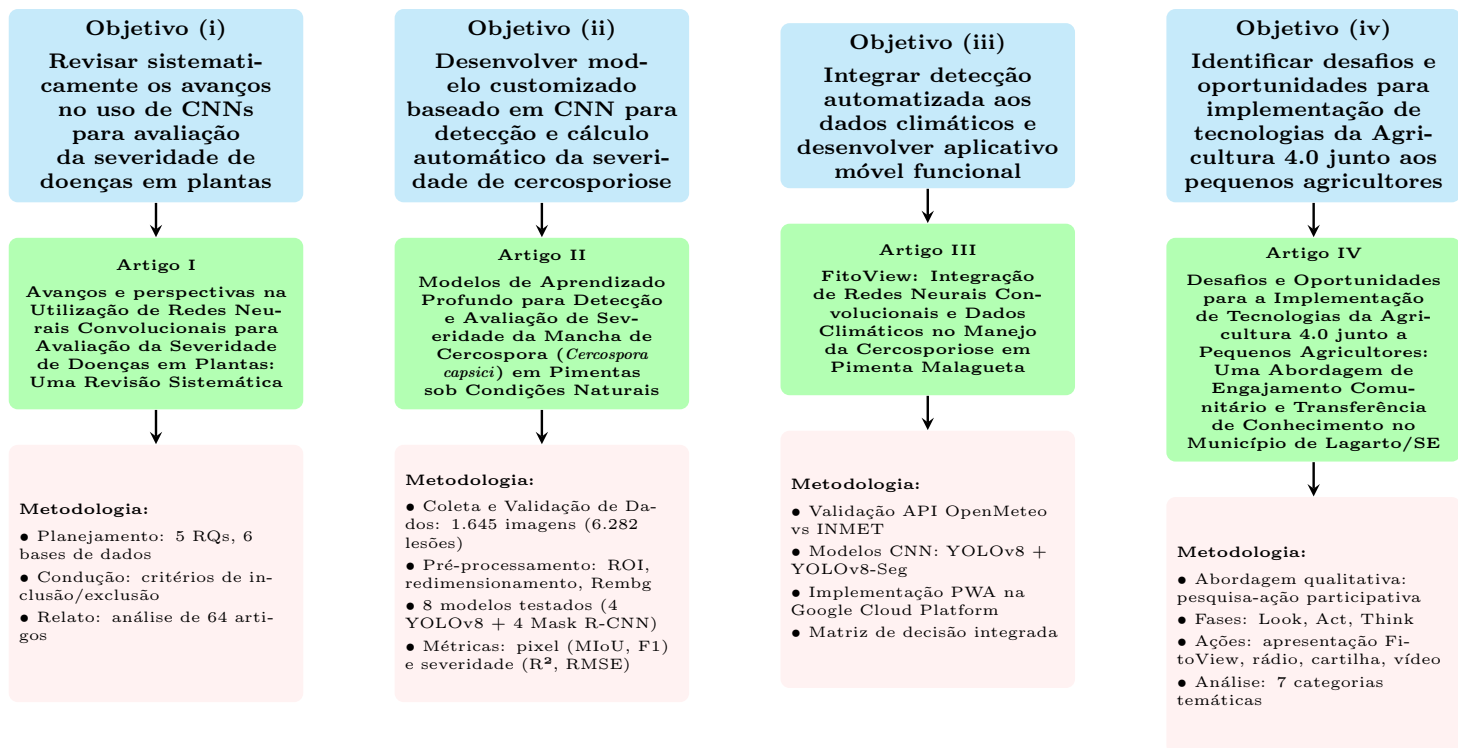
Aplicações Web Progressivas (PWAs) representam uma abordagem promissora para superar barreiras de acesso, pois permitem acesso direto por meio de navegadores web

móveis sem exigir instalação de aplicativo nativo, reduzindo barreiras de implantação para usuários finais (Gauntlett, 2017). PWAs combinam as melhores características de aplicativos web e nativos, oferecendo funcionalidades offline, notificações push e acesso a recursos do dispositivo, enquanto mantêm a facilidade de acesso através de URLs (Gauntlett, 2017). Além disso, arquiteturas baseadas em nuvem permitem que o processamento computacionalmente intensivo seja realizado em servidores remotos, reduzindo os requisitos de hardware dos dispositivos dos usuários (Wang *et al.*, 2010). Esta abordagem é particularmente importante para aplicações de inteligência artificial, que frequentemente requerem recursos computacionais significativos que não estão disponíveis em smartphones de baixo custo (Kamilaris *et al.*, 2018).

3 Materiais e Métodos

Esta pesquisa foi desenvolvida seguindo uma abordagem metodológica integrada de natureza quali-quantitativa que combina revisão sistemática da literatura, desenvolvimento e validação de modelos de aprendizado profundo, integração de tecnologias digitais e pesquisa aplicada com agricultores familiares. A metodologia geral percorre quatro etapas principais, cada uma correspondendo a um dos artigos que compõem a pesquisa e vinculada a um dos objetivos específicos estabelecidos, conforme ilustrado na Figura 4.

Figura 4 – Diagrama da metodologia geral.



3.1 Revisão Sistemática da Literatura (Artigo I)

O primeiro artigo desta tese, vinculado ao objetivo específico (i) de revisar sistematicamente os avanços no uso de redes neurais convolucionais para avaliação da severidade de doenças em plantas, consistiu em uma revisão sistemática da literatura sobre o uso de Redes Neurais Convolucionais (CNNs) para avaliação da severidade de doenças em plantas. A metodologia seguiu o protocolo desenvolvido por Keele *et al.* (2007), que fornece uma abordagem sistemática para garantir rigor e consistência em revisões de literatura. O

processo foi organizado em três etapas bem definidas: (1) Planejamento da revisão, (2) Condução da revisão e (3) Relato da revisão.

A etapa de planejamento iniciou-se com a definição dos objetivos da revisão e a especificação de cinco questões de pesquisa (RQs) específicas. Em seguida, foram desenvolvidos critérios de busca incluindo palavras-chave relevantes como "CNN" e "severidade de doenças em plantas" para construir as strings de busca finais. Foram selecionadas seis bases de dados de alta qualidade: IEEE Xplore, Scopus, Web of Science, ACM Digital Library, PubMed e ScienceDirect, além de conferências relevantes na área.

A etapa de condução envolveu a aplicação de critérios de inclusão e exclusão. Os critérios de inclusão consideraram: (i) estudos que empregaram modelos CNN para determinar a severidade de doenças em plantas; (ii) artigos publicados em periódicos e conferências indexadas. Após a remoção de duplicatas e triagem de títulos e resumos, os artigos restantes passaram por triagem de texto completo e avaliação de qualidade utilizando cinco critérios: clareza do objetivo, contextualização, metodologia, inovação técnica e clareza dos achados. Foram analisados 64 artigos que atenderam aos critérios estabelecidos.

A etapa de relato apresentou os resultados da revisão, começando com uma visão geral dos resultados, seguida pelas respostas específicas às cinco questões de pesquisa, identificando tendências, lacunas e direções futuras para a pesquisa na área.

3.2 Desenvolvimento e Validação de Modelos CNN (Artigo II)

O segundo artigo, vinculado ao objetivo específico (ii) de desenvolver um modelo customizado baseado em CNN para detecção e cálculo automático da severidade de cercosporiose em folhas de pimenta malagueta, focou no desenvolvimento e validação de modelos customizados de aprendizado profundo para detecção e quantificação da severidade da cercosporiose em folhas de pimenta malagueta. A metodologia compreendeu quatro etapas principais: coleta de dados, preparação do conjunto de dados, treinamento e avaliação de desempenho.

A coleta de dados foi realizada entre 15 de março e 31 de maio de 2023, em uma plantação localizada em Lagarto, Estado de Sergipe, Brasil (Lat: -10.9145, Long: -37.6639). Um total de 1.645 imagens RGB de folhas de pimenta malagueta (*Capsicum frutescens*) foram capturadas utilizando um smartphone, sob condições naturais de campo, incluindo folhas saudáveis e afetadas pela cercosporiose.

O pré-processamento das imagens incluiu aplicação de região de interesse (ROI) para efeito de zoom, redimensionamento para formato padrão de 640×640 pixels e remoção automática de planos de fundo utilizando a biblioteca *Rembg*. Todas as 6.282 lesões identificadas foram anotadas manualmente usando a ferramenta da API do *Roboflow*, seguindo as especificações do conjunto de dados COCO. As amostras foram divididas

aleatoriamente em conjuntos de treinamento (1.040 imagens, 3.943 lesões), validação (294 imagens, 1.131 lesões) e teste (309 imagens, 1.208 lesões).

Foram testados oito modelos: quatro variantes YOLOv8-Seg (nano, small, medium e large) e quatro modelos Mask R-CNN (com backbones ResNet-50 e ResNet-101, utilizando FPN ou C4). As variantes YOLOv8-Seg diferem em tamanho e capacidade de processamento, permitindo avaliar o trade-off entre precisão e velocidade; os modelos Mask R-CNN foram configurados com diferentes backbones e neck (FPN ou C4), permitindo comparação entre arquiteturas de extração de características. Os modelos pré-treinados foram treinados usando o ambiente Google Colab com GPU NVIDIA Tesla T4, seguindo 300 épocas para YOLOv8 e 19.500 iterações para Mask R-CNN, com taxa de aprendizado de 0.001. As 300 épocas seguem as recomendações da Ultralytics; para o Mask R-CNN, o equivalente em iterações foi calculado com base no tamanho do conjunto de treinamento (1.040 imagens) e batch size de 16, conforme detalhado no Capítulo II.

A avaliação de desempenho foi realizada em dois níveis: (i) nível de pixel, utilizando métricas de acurácia, precisão, revocação, F1-score e MIoU (Mean Intersection over Union); e (ii) nível de severidade, utilizando regressão linear, coeficiente de determinação (R^2), RMSE (Root Mean Square Error) e matrizes de confusão para classificação dos níveis de severidade. A severidade foi categorizada em sete classes baseadas em escalas diagramáticas adaptadas da literatura.

3.3 Desenvolvimento de Sistema Integrado de Apoio à Decisão (Artigo III)

O terceiro artigo, vinculado ao objetivo específico (iii) de integrar a detecção automatizada aos dados climáticos locais e desenvolver um aplicativo móvel funcional que ofereça informações relevantes ao manejo da cultura, apresentou o desenvolvimento do FitoView, Um protótipo de sistema de apoio à decisão móvel baseado em nuvem, que integra modelos de deep learning e previsões meteorológicas em tempo real. A metodologia envolveu três componentes principais: validação de dados meteorológicos, desenvolvimento de modelos CNN customizados e implementação da aplicação web progressiva.

Para a aquisição de dados climáticos, foi utilizada a API OpenMeteo, um serviço meteorológico de código aberto que fornece dados de previsão e histórico meteorológico agregando informações de modelos líderes de previsão numérica do tempo. A validação dos dados foi realizada comparando séries temporais horárias de temperatura do ar, radiação solar e umidade relativa da API com registros de estações meteorológicas automáticas do INMET em quatro municípios de Sergipe (Aracaju, Nossa Senhora da Glória, Brejo Grande e Itabaianinha), utilizando métricas de MAE, RMSE, coeficiente de correlação de Pearson (r) e coeficiente de determinação (R^2).

O desenvolvimento de modelos CNN customizados incluiu dois componentes: (i) um modelo YOLOv8 para detecção e classificação de doenças, treinado com conjunto de

dados composto por 247 imagens (149 treino, 49 validação, 49 teste) expandidas para 447 imagens após aumento de dados, abrangendo cinco classes: mancha-de-cercóspora, deficiência nutricional, edema, folhas saudáveis e mancha bacteriana; e (ii) um modelo YOLOv8-Seg para avaliação de severidade, previamente desenvolvido e validado no Artigo II.

A implementação da aplicação seguiu a arquitetura de Aplicação Web Progressiva (PWA), implantada na Google Cloud Platform, permitindo acesso via navegadores web móveis sem necessidade de instalação. O sistema integra análise de imagens baseada em CNN com dados de previsão meteorológica através de uma matriz de decisão que considera três dimensões: severidade da doença avaliada por IA, previsões de risco climático de 48 horas e condições ideais de pulverização, gerando quatro cenários de manejo contextualizados.

3.4 Engajamento Comunitário e Transferência de Conhecimento (Artigo IV)

O quarto artigo, vinculado ao objetivo específico (iv) de identificar desafios e oportunidades para a implementação de tecnologias da Agricultura 4.0 junto aos pequenos agricultores da região estudada, investigou a dimensão social da adoção tecnológica através de uma abordagem de pesquisa-ação participativa (Stringer, 2014) no município de Lagarto/SE. A metodologia seguiu o ciclo iterativo de três fases: Look (observação e compreensão do contexto), Act (implementação de ações de engajamento) e Think (análise reflexiva e sistematização).

A fase Look iniciou com visita exploratória ao Perímetro Irrigado Piauí, identificando a cercosporiose como problema prioritário e estabelecendo relações com técnicos e agricultores. Na fase Act, foram implementadas ações de engajamento comunitário incluindo: apresentação do sistema FitoView em reunião do Movimento Camponês Livre (MCP) com participação de 30-40 agricultores, técnicos e lideranças; entrevista em programa de rádio local; desenvolvimento de cartilha educativa com linguagem acessível; e elaboração de vídeo demonstrativo. A fase *Think* compreendeu análise reflexiva fundamentada na vivência do pesquisador durante as três fases, identificando sete categorias temáticas organizadas em duas dimensões: desafios (limitações de conectividade, necessidade de capacitação digital, barreiras econômicas) e oportunidades (alta penetração de smartphones, interesse demonstrado pelos agricultores, potencial de parcerias com organizações locais, demanda por ferramentas que reduzam uso de agrotóxicos). As categorias emergiram da reflexão sistemática sobre observações diretas, interações formais e desenvolvimento de materiais educativos, garantindo triangulação metodológica e robustez na identificação dos temas centrais relacionados à adoção da tecnologia.

3.5 Integração Metodológica

A integração entre os quatro artigos ocorre de forma sequencial e complementar: a revisão sistemática (Artigo I) forneceu o estado da arte e identificou lacunas na literatura; o desenvolvimento de modelos CNN (Artigo II) validou técnicas específicas para o caso de estudo da cercosporiose; o sistema integrado (Artigo III) combinou os modelos desenvolvidos com dados meteorológicos em uma aplicação prática; e o engajamento comunitário e transferência de conhecimento (Artigo IV) identificou desafios e oportunidades para a implementação das tecnologias desenvolvidas junto aos pequenos agricultores, através de uma abordagem participativa baseada em ações de divulgação, materiais educativos e diálogos com a comunidade agrícola local.

Referências

AGRIOS, George N. **Plant Pathology**. 5th. San Diego, CA: Academic Press, 2005.

AQEEL-UR-REHMAN; SHAIKH, Z. A. **Smart Agriculture: Application of Modern High Performance Networks**. [S. l.]: Bentham Science Publishers Ltd, 2009. p. 120–129.

ARAÚJO *et al.* Total precipitation and air temperature data obtained from ERA5-Land reanalysis: validation and accuracy. **Revista Caatinga**, v. 38, e12578, 2025.

BADRINARAYANAN *et al.* Segnet: A deep convolutional encoder-decoder architecture for image segmentation. **IEEE transactions on pattern analysis and machine intelligence**, IEEE, v. 39, n. 12, p. 2481–2495, 2017.

BARBEDO, J.G.A. Factors influencing the use of deep learning for plant disease recognition. **Biosystems engineering**, Elsevier, v. 172, p. 84–91, 2018.

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

BARBEDO, JGA; GARCIA, J. Digital image processing techniques for detecting, quantifying and classifying plant diseases. *SpringerPlus* 2: 660, 2013.

BARRETT, C.B. *et al.* On the structural transformation of rural Africa. **World Development**, v. 142, p. 105454, 2021.

BAUMÜLLER, Heike. The little we know: An exploratory literature review on the utility of mobile phone-enabled services for smallholder farmers. **Journal of International Development**, Wiley Online Library, v. 30, n. 1, p. 134–154, 2018.

BOCHKOVSKIY *et al.* **YOLOv4: Optimal Speed and Accuracy of Object Detection**. [S. l.: s. n.], 2020. arXiv: 2004.10934 [cs.CV]. Disponível em: <https://arxiv.org/abs/2004.10934>.

BOCK, CH *et al.* Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging. **Critical reviews in plant sciences**, Taylor & Francis, v. 29, n. 2, p. 59–107, 2010.

BOLYA, Daniel *et al.* Yolact: Real-time instance segmentation. *In: PROCEEDINGS of the IEEE/CVF international conference on computer vision*. [S. l.: s. n.], 2019. p. 9157–9166.

CARNEIRO, F. F. *et al.* **Atlas Geográfico do Uso de Agrotóxicos no Brasil e Conexões com a União Europeia**. São Paulo: São Paulo: FFLCH-USP, 2017.

CHEN, Liang-Chieh *et al.* Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs. **IEEE transactions on pattern analysis and machine intelligence**, IEEE, v. 40, n. 4, p. 834–848, 2017.

CODERSE. **Perímetro Irrigado Piauí**. [S. l.: s. n.], 2023. Disponível em: <https://coderse.se.gov.br/perimetros/perimetros-irrigados/perimetro-irrigado-piaui-2/?query-12-page=2>. Acesso em: 21 de novembro de 2023.

DAMALAS, Christos A.; ELEFTHEROHORINOS, Ilias G. Pesticide exposure, safety issues, and risk assessment indicators. **International Journal of Environmental Research and Public Health**, MDPI, v. 8, n. 5, p. 1402–1419, 2011.

DECLARATION, Stockholm. Declaration of the United Nations conference on the human environment. URL= <http://www.unep.org/Documents.Multilingual/Default.asp>, 1972.

DEL PONTE, and others. Validation of a simulation model for leaf rust epidemics in Brazilian wheat cultivars. **Phytopathology**, v. 95, n. 4, p. 487–495, 2005.

ELKINGTON, John; ROWLANDS, Ian H. Cannibals with forks: The triple bottom line of 21st century business. **Alternatives Journal**, Alternatives Media, Inc., v. 25, n. 4, p. 42, 1999.

FEENSTRA, Gail; CAMPBELL, David; CHANEY, David. **Community Food Systems: Sustaining Farms and People in the Emerging Economy: Conference Proceedings, Davis, California, October 2-3, 1996**. [S. l.]: University of California, Division of Agriculture e Natural Resources ..., 1997.

GAUNTLETT, Alex. **Progressive Web Apps: Escaping Tabs Without Losing Our Soul**. [S. l.: s. n.], 2017. <https://alistapart.com/article/progressive-web-apps/>. Acesso em: 2024.

GIRSHICK, Ross. Fast r-cnn. *In: PROCEEDINGS of the IEEE international conference on computer vision*. [S. l.: s. n.], 2015. p. 1440–1448.

GIRSHICK, Ross *et al.* Rich feature hierarchies for accurate object detection and semantic segmentation. *In: PROCEEDINGS of the IEEE conference on computer vision and pattern recognition*. [S. l.: s. n.], 2014. p. 580–587.

GOODFELLOW *et al.* **Deep learning**. [S. l.]: MIT press, 2016.

HE, Kaiming; GKIOXARI, Georgia *et al.* Mask r-cnn. *In: PROCEEDINGS of the IEEE international conference on computer vision*. [S. l.: s. n.], 2017. p. 2961–2969.

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

HUANG, Gao *et al.* Densely connected convolutional networks. *In: PROCEEDINGS of the IEEE conference on computer vision and pattern recognition*. [S. l.: s. n.], 2017. p. 4700–4708.

IBGE. **Censo Agropecuário 2017: resultados definitivos**. Rio de Janeiro: IBGE, 2019.

JACOBI, Pedro. Meio ambiente e sustentabilidade. *In: O MUNICÍPIO NO SÉCULO XXI: CENÁRIOS E PERSPECTIVAS*. São Paulo: Cepam, 1999. p. 175–183.

JOCHER *et al.* **Ultralytics YOLO**. [S. l.: s. n.], 2023. Software disponível sob licença AGPL-3.0. Disponível em: <https://github.com/ultralytics/ultralytics>.

KAMILARIS *et al.* Deep learning in agriculture: A survey. **Computers and Electronics in Agriculture**, v. 147, p. 70–90, 2018.

KEELE, Staffs *et al.* **Guidelines for performing systematic literature reviews in software engineering**. Durham, 2007.

KRIZHEVSKY *et al.* Imagenet classification with deep convolutional neural networks. **Advances in neural information processing systems**, v. 25, 2012.

LAMICHHANE, Jay Ram *et al.* Toward a reduced reliance on conventional pesticides in European agriculture. **Plant Disease**, APS Publications, v. 100, n. 1, p. 10–24, 2016.

LECUN, Yann *et al.* Deep learning. **Nature**, Nature Publishing Group UK London, v. 521, n. 7553, p. 436–444, 2015.

LECUN, Yann *et al.* Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, Ieee, v. 86, n. 11, p. 2278–2324, 1998.

LIAKOS, Konstantinos G. *et al.* Machine learning in agriculture: A review. **Sensors**, MDPI, v. 18, n. 8, p. 2674, 2018.

LIU, Jun; WANG, Xuwei. Plant diseases and pests detection based on deep learning: a review. **Plant Methods**, Springer, v. 17, p. 1–18, 2021.

LIU, Wei; ANGUELOV, Dragomir *et al.* Ssd: Single shot multibox detector. *In*: SPRINGER. COMPUTER Vision–ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part I 14. [*S. l.: s. n.*], 2016. p. 21–37.

LIU, Yansui; ZHOU, Yang; WU, Wenxiang. Assessing the impact of population, income and technology on energy consumption and industrial pollutant emissions in China. **Applied Energy**, Elsevier, v. 184, p. 1016–1025, 2020.

LONG *et al.* Fully convolutional networks for semantic segmentation. *In*: PROCEEDINGS of the IEEE conference on computer vision and pattern recognition. [*S. l.: s. n.*], 2015. p. 3431–3440.

MADDEN, and others. **The study of plant disease epidemics**. St. Paul, MN: APS Press, 2007.

MASSRUHÁ, Silvia Maria Fonseca Silveira; LEITE, Maria Angelica de Andrade. Agro 4.0: rumo à agricultura digital. *In*: MAGNONI JÚNIOR, Lourenço *et al.* (ed.). **Big Data e Internet das Coisas: compreendendo o ordenamento jurídico brasileiro**. São Paulo: CGI.br, 2017. p. 8–35.

MEADOWS, Donella H; RANDERS, Jorgen. Dennis L. Meadows. **Limits to Growth-The 30 year Update**, 1972.

NAIR *et al.* Rectified linear units improve restricted boltzmann machines. *In*: PROCEEDINGS of the 27th international conference on machine learning (ICML-10). [*S. l.: s. n.*], 2010. p. 807–814.

NUTTER JR., F. W.; TENG, P. S.; SHOKES, F. M. Disease assessment terms and concepts. **Plant Disease**, v. 75, n. 11, p. 1187–1188, 1991.

OLIVEIRA RIBEIRO, Luiz Augusto de *et al.* Panorama sobre o uso de agrotóxicos no Brasil (2009-2019): Riscos, benefícios e alternativas. **Revista Brasileira de Meio Ambiente**, v. 10, n. 2, 2022.

PRETTY, Jules. Overview to four volumes: Sustainable agriculture and food. **Sustainable agriculture and food**, v. 1, 2008.

PROENÇA *et al.* Tecnologias da informação e comunicação e a agricultura familiar: Desafios e perspectivas. **Revista de Economia e Sociologia Rural**, v. 53, n. 1, p. 85–102, 2015.

RATAN, Phani. **What is the Convolutional Neural Network Architecture?** [*S. l.: s. n.*], 2020. <https://www.analyticsvidhya.com/blog/2020/10/what-is-the-convolutional-neural-network-architecture/>. Acesso em: 2024.

REDMON, Joseph *et al.* You only look once: Unified, real-time object detection. *In: PROCEEDINGS of the IEEE conference on computer vision and pattern recognition*. [*S. l.: s. n.*], 2016. p. 779–788.

REGANOLD, John P; WACHTER, Jonathan M. Organic agriculture in the twenty-first century. **Nature plants**, Nature Publishing Group, v. 2, n. 2, p. 1–8, 2016.

REN, Shaoqing *et al.* Faster r-cnn: Towards real-time object detection with region proposal networks. **Advances in neural information processing systems**, v. 28, 2015.

ROGERS, E.M. **Diffusion of Innovations**. 5th. New York, USA: Free Press, 2003.

RONNEBERGER *et al.* U-net: Convolutional networks for biomedical image segmentation. *In: SPRINGER. MEDICAL Image Computing and Computer-Assisted Intervention–MICCAI 2015: 18th International Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III* 18. [*S. l.: s. n.*], 2015. p. 234–241.

ROSE, David C. *et al.* Agriculture 4.0: Making it work for people, production, and the planet. **Land Use Policy**, Elsevier, v. 100, p. 104933, 2021.

SANTOS, R.B. *et al.* PLANEJAMENTO DA PULVERIZAÇÃO DE FUNGICIDAS EM FUNÇÃO DAS VARIÁVEIS METEOROLÓGICAS NA REGIÃO DE SINOP-MT (Planning of fungicide spraying according to meteorological variables in the Sinop-MT region). **Global Science and Technology**, v. 6, n. 1, 2013. (In Portuguese).

SAVARY, S. *et al.* The global burden of pathogens and pests on major food crops. **Nature Ecology & Evolution**, v. 3, n. 3, p. 430–439, 2019.

SCHWAB, Klaus. **The Fourth Industrial Revolution**. New York: Crown Business, 2017.

SCOLIN, and others. Optimizing action thresholds for improved control of soybean powdery mildew with fungicides. **Tropical Plant Pathology**, v. 48, n. 2, p. 236–240, 2023.

SHI, Tingting *et al.* Recent advances in plant disease severity resoluishment using convolutional neural networks. **Scientific Reports**, Nature Publishing Group UK London, v. 13, n. 1, p. 2336, 2023.

SIMONYAN *et al.* Very deep convolutional networks for large-scale image recognition. **arXiv preprint arXiv:1409.1556**, 2014.

STOCKMAN, George; SHAPIRO, Linda G. **Computer vision**. [S. l.]: Prentice Hall PTR, 2001.

STRINGER, Ernest T. **Action Research**. 4. ed. Los Angeles: SAGE Publications, 2014.

SUPERANNOTATE. **Image segmentation detailed overview [Updated 2024]**. [S. l.: s. n.], 2023. <https://www.superannotate.com/blog/image-segmentation-for-machine-learning>. Acesso em: 2024.

SZEGEDY, Christian *et al.* Going deeper with convolutions. *In*: PROCEEDINGS of the IEEE conference on computer vision and pattern recognition. [S. l.: s. n.], 2015. p. 1–9.

THENKABAIL, Prasad S; LYON, John G; HUETE, Alfredo. Fifty Years of Advances in Hyperspectral Remote Sensing of Agriculture and Vegetation—Summary, Insights, and Highlights of Volume III: Biophysical and Biochemical Characterization and Plant Species Studies. *In*: BIOPHYSICAL and biochemical characterization and plant species studies. [S. l.]: CRC Press, 2018. p. 303–341.

TOO, E.C. *et al.* A comparative study of fine-tuning deep learning models for plant disease identification. **Computers and Electronics in Agriculture**, v. 161, p. 272–279, 2019.

UNITED NATIONS. **Transforming our world: the 2030 Agenda for Sustainable Development**. [S. l.]: United Nations, 2015. Disponível em: <https://sdgs.un.org/2030agenda>.

WANG, Lizhe *et al.* Cloud computing: a perspective study. **New Generation Computing**, Springer, v. 28, n. 2, p. 137–146, 2010.

WCED, Special Working Session. World commission on environment and development. **Our common future**, v. 17, n. 1, p. 1–91, 1987.

WEERSINK, Alfons *et al.* Opportunities and challenges for big data in agricultural and environmental analysis. **Annual Review of Resource Economics**, Annual Reviews, v. 10, p. 19–37, 2021.

ZEILER *et al.* Visualizing and understanding convolutional networks. *In:* SPRINGER. EUROPEAN Conference on Computer Vision. [*S. l.: s. n.*], 2014. p. 818–833.

ZHAI, Zhaoyu *et al.* Decision support systems for agriculture 4.0: Survey and challenges. **Computers and Electronics in Agriculture**, Elsevier, v. 170, p. 105256, 2020. DOI: 10.1016/j.compag.2020.105256. Disponível em: <https://doi.org/10.1016/j.compag.2020.105256>.

ZIPPENFENIG, P. **Open-Meteo.com Weather API (Version 1.0) [Computer software]**. [*S. l.*]: Zenodo, 2023. DOI: 10.5281/zenodo.10007159. Disponível em: <https://doi.org/10.5281/zenodo.10007159>.

CAPÍTULO I

AVANÇOS E PERSPECTIVAS NA UTILIZAÇÃO DE REDES NEURAIIS CONVOLUCIONAIS PARA AVALIAÇÃO DA SEVERIDADE DE DOENÇAS EM PLANTAS: UMA REVISÃO SISTEMÁTICA¹

RESUMO

Além de causar perdas na produção, as doenças em plantas geram danos ambientais devido ao uso indiscriminado de pesticidas. Inicialmente limitadas à detecção de doenças, as aplicações de Redes Neurais Convolucionais - *Convolutional Neural Networks* (CNNs) agora incluem soluções automáticas para cálculo e classificação da severidade. A pesquisa nesse campo está em constante evolução, com novas abordagens e métodos, ressaltando a necessidade de revisões que delineiem o panorama atual e orientem os pesquisadores no desenvolvimento de novas metodologias. Este artigo realiza uma revisão sistemática da literatura para examinar os aspectos científicos, a evolução atual dos métodos, seus resultados e lacunas potenciais para futuras investigações. Após buscas em seis bases de dados distintas e conferências relevantes, bem como a aplicação de critérios de inclusão e exclusão, foram analisados 64 artigos, abordando cinco questões específicas de revisão. Os resultados indicam um crescente interesse no uso de CNNs para avaliação da severidade de doenças em plantas. Métodos baseados em classificação e segmentação com CNNs têm sido empregados, com uma tendência para *frameworks* aprimorados e híbridos, que representam cerca de 50% dos estudos. Redes neurais leves, redes de Memória de Longo e Curto Prazo - *Long Short-Term Memory* (CNN-LSTM), mecanismos de atenção, aprendizado por transferência, e combinações com lógica *fuzzy* e Redes Adversárias Generativas - *Generative Adversarial Networks* (GANs) estão ganhando destaque. Doenças bacterianas e fúngicas em culturas como tomate, trigo e arroz são as mais estudadas, representando 42% das pesquisas. Os resultados indicam que pesquisas futuras devem focar na ampliação de conjuntos de dados em ambientes naturais, diversificação das culturas estudadas e melhoria da robustez e generalização dos modelos. Além disso, é necessário explorar métodos aprimorados, incluindo aprendizado por transferência, aprendizado de poucos exemplos

(*few-shot learning*) e aprendizado profundo autossupervisionado, além de desenvolver modelos mais leves adequados para avaliação em tempo real em condições de campo.

Palavras-chave: Redes Neurais Convolucionais; CNN; Severidade de Doenças em Plantas; Inteligência Artificial

¹ Trabalho publicado na revista *Smart Agricultural Technology*, ISSN: 2772-3755, Volume 9, December 2024, 100573, JCR 2024: 5,7, Q1 nas categorias 'Agriculture, Multidisciplinary'. DOI: <https://doi.org/10.1016/j.atech.2024.100573>

ADVANCES AND PERSPECTIVES IN THE USE OF CONVOLUTIONAL NEURAL NETWORKS FOR PLANT DISEASE SEVERITY ASSESSMENT: A SYSTEMATIC REVIEW

ABSTRACT

In addition to causing production losses, plant diseases generate environmental damage due to indiscriminate use of pesticides. Initially limited to disease detection, Convolutional Neural Network (CNN) applications now include automatic solutions for severity calculation and classification. Research in this field is constantly evolving, with new approaches and methods, highlighting the need for reviews that outline the current panorama and guide researchers in developing new methodologies. This article conducts a systematic literature review to examine the scientific aspects, current evolution of methods, their results, and potential gaps for future investigations. After searches in six distinct databases and relevant conferences, as well as the application of inclusion and exclusion criteria, 64 articles were analyzed, addressing five specific review questions. Results indicate a growing interest in using CNNs for plant disease severity assessment. Classification and segmentation methods with CNNs have been employed, with a trend toward enhanced and hybrid frameworks, representing about 50% of studies. Lightweight neural networks, Long Short-Term Memory (CNN-LSTM) networks, attention mechanisms, transfer learning, and combinations with fuzzy logic and Generative Adversarial Networks (GANs) are gaining prominence. Bacterial and fungal diseases in crops such as tomato, wheat, and rice are the most studied, representing 42% of research. Results indicate that future research should focus on expanding datasets in natural environments, diversifying studied crops, and improving model robustness and generalization. Furthermore, it is necessary to explore enhanced methods, including transfer learning, few-shot learning, and self-supervised deep learning, in addition to developing lighter models suitable for real-time assessment in field conditions.

Keywords: Convolutional Neural Networks; CNN; Plant disease severity; Artificial Intelligence

1 Introdução

As doenças em plantas e problemas fitossanitários são uma das principais causas de redução na produção e perdas de safra em cultivos. Estima-se uma redução de 30 a 40% de todo o potencial de produção (Flood, 2010). A identificação antecipada permite a adoção de medidas preventivas, reduzindo a dependência do uso excessivo de produtos químicos (Khakimov *et al.*, 2022).

Normalmente, os pesquisadores medem a severidade de doenças em folhas de plantas quantificando a porcentagem de uma unidade vegetal que apresenta sintomas visíveis (Madden, 2007). Uma estratégia clássica para avaliar a severidade de doenças foliares é o uso de escalas diagramáticas. Essas escalas representam folhas de plantas com sintomas em diferentes níveis de severidade. No entanto, a subjetividade dos avaliadores e as variações na percepção visual podem limitar sua eficácia (Martins *et al.*, 2004). Além disso, a dependência de categorias predefinidas pode negligenciar variações sutis na severidade, reduzindo a precisão (Campbell *et al.*, 1990). A avaliação da severidade de doenças usando escalas diagramáticas exige tempo, mão de obra qualificada e, em alguns casos, treinamento especializado, o que pode ser impraticável ou oneroso (Madden, 2007).

O avanço das tecnologias de processamento digital de imagens possibilitou o desenvolvimento de novas técnicas capazes de determinar a severidade de doenças em plantas (Bock, 2011). Essas abordagens dependem da captura de imagens de plantas afetadas e da análise computacional das características visuais das lesões ou sintomas (Singh *et al.*, 2016). Softwares como ImageJ (Schneider *et al.*, 2012) e Fiji (Schindelin *et al.*, 2012) permitem ao usuário manipular a imagem para obter dados sobre a área da folha e das lesões. No entanto, ainda é necessária a intervenção humana para determinar a cor das lesões, o que pode causar confusão na distinção entre lesões relacionadas a doenças e não relacionadas, aumentando o risco de subestimação ou superestimação da severidade (Amorim *et al.*, 2016).

Ferramentas baseadas em Inteligência Artificial (IA) têm sido estudadas e aplicadas em diversas áreas. Em particular, as Redes Neurais Convolucionais (CNNs) se mostraram eficazes em tarefas de processamento de imagens, assim como em diversas aplicações, como em tarefas de processamento de linguagem natural (PLN), como classificação de sentenças (Rhanoui *et al.*, 2019), reconhecimento de fala (Passricha; Aggarwal, 2019), e previsão climática, incluindo temperatura (Vos *et al.*, 2021), previsão de chuvas e enchentes (Waqas *et al.*, 2023b,a).

Estudos recentes investigaram sistemas automáticos para detectar e determinar a severidade de doenças em plantas usando CNNs, demonstrando uma eficácia notável para atingir esse objetivo (Barbedo, 2013). As CNNs se destacam na detecção de doenças em plantas, evidenciando sua capacidade de extrair características e realizar classificações simultaneamente em diversos estudos (Toda; Okura, 2019; Barburiceanu *et al.*, 2021).

As CNNs oferecem vantagens significativas em relação aos métodos tradicionais, superando suas limitações ao identificar automaticamente a severidade da doença por meio da análise pixel a pixel do tecido da lesão. Elas conseguem processar grandes conjuntos de dados de forma eficiente e extrair automaticamente características relevantes das imagens das plantas, eliminando a necessidade de trabalho manual e reduzindo a subjetividade humana. (Lu; Tan; Jiang, 2021; Shi *et al.*, 2023). Esse processo automatizado não apenas aprimora a precisão na classificação da doença e na estimativa da severidade, mas também melhora a velocidade e a capacidade de generalização em comparação com abordagens convencionais (Kumari *et al.*, 2024; Menon *et al.*, 2021).

Uma estrutura padrão de CNN compreende várias camadas: entrada, oculta, convolucional, pooling, totalmente conectada e de saída. O treinamento envolve o uso de uma função de custo (*cost function*) para aprimorar o desempenho da rede. Funções de ativação e métodos de regularização, como camadas de *dropout*, podem ser empregados para otimizar o desempenho do modelo e promover a generalização (Hamed *et al.*, 2023).

Ao longo dos anos, os modelos baseados em CNNs fizeram avanços significativos em classificação de imagens, detecção de objetos e segmentação semântica (Geng *et al.*, 2018). Marcos notáveis incluem o desenvolvimento da arquitetura LeNet-5 (LeCun *et al.*, 1998) para o reconhecimento de dígitos manuscritos. Em 2012, o artigo intitulado "ImageNet classification with deep convolutional neural networks" (Krizhevsky *et al.*, 2012) demonstrou o potencial das CNNs para aprender características de imagens complexas e hierárquicas. Esse trabalho pioneiro marcou o início de uma nova era na visão computacional e no campo mais amplo do aprendizado profundo, impulsionando o progresso e a inovação significativos.

Modelos subsequentes têm constantemente avançado o campo, aprimorando a precisão e a eficiência. Contribuições notáveis incluem VGGNet, GoogLeNet, ResNet e DenseNet (Simonyan *et al.*, 2014; Szegedy *et al.*, 2015; He; Zhang *et al.*, 2016; Huang *et al.*, 2017). À medida que as CNNs evoluem, uma contínua onda de novos modelos emerge, cada um implementando características distintas. Redes leves, como SqueezeNet, MobileNet, ShuffleNet, Xception e EfficientNet (Iandola *et al.*, 2016; Howard *et al.*, 2017; Zhang, X. *et al.*, 2018; Chollet, 2017; Tan; Le, 2019), exemplificam essa tendência. Para detecção de objetos, temos R-CNN, Fast R-CNN, Faster R-CNN, YOLO e SSD (Girshick *et al.*, 2014; Girshick, 2015; Ren *et al.*, 2015; Redmon *et al.*, 2016; Liu, Wei *et al.*, 2016). Da mesma forma, para tarefas de segmentação, modelos como FCN, SegNet, U-Net, PSPNet, DeepLab e Mask RCNN (Long *et al.*, 2015; Badrinarayanan *et al.*, 2017; Ronneberger *et al.*, 2015; Zhao, H. *et al.*, 2017; Chen, L.-C. *et al.*, 2017; He; Gkioxari *et al.*, 2017), entre outros, demonstraram um desempenho excepcional e possuem considerável valor na pesquisa.

Wang *et al.* (2017) introduziram o uso de métodos de CNN para estimar automaticamente a severidade de doenças em plantas. Eles utilizaram várias arquiteturas de

classificação para identificar quatro categorias de severidade da podridão negra em maçãs, alcançando uma precisão geral de 90,4% no conjunto de teste. Desde então, pesquisas têm explorado o uso de CNNs para automatizar a detecção, classificação e determinação da severidade de doenças em plantas. Alguns estudos focam apenas na detecção de doenças, enquanto outros detectam e classificam as doenças em diferentes categorias. Poucos estudos se concentram na detecção e medição da severidade da doença. Nas próximas seções, pretendemos realizar uma revisão sistemática da literatura para analisar os avanços mais recentes, os desafios e as oportunidades deste campo.

A estrutura deste artigo está organizada da seguinte forma: a Seção 2 apresenta uma revisão abrangente dos trabalhos relacionados, com foco nos estudos existentes que aplicam CNNs na avaliação de doenças em plantas. A Seção 3 introduz brevemente as CNNs, delineando seus princípios fundamentais. A Seção 4 detalha a metodologia de pesquisa empregada nesta revisão, incluindo os critérios para seleção dos estudos e a abordagem analítica utilizada para sintetizar os resultados. A Seção 5 discute os achados da revisão, destacando as principais percepções e tendências na literatura. Por fim, a conclusão resume as contribuições desta revisão e sugere direções potenciais para futuras pesquisas na área.

2 Trabalhos relacionados

Ao longo dos anos, houve um aumento significativo nas pesquisas sobre identificação e análise automática de doenças em plantas. Como resultado, há uma demanda crescente por revisões abrangentes neste campo. Atualmente, as revisões existentes cobrem uma ampla gama de métodos, incluindo tecnologias gerais de visão computacional (Bock *et al.*, 2020; Ngugi, 2021), aplicações de aprendizado de máquina e aprendizado profundo (Jackulin *et al.*, 2022; Ahmad *et al.*, 2023; Suganya *et al.*, 2022; Bondre *et al.*, 2023; Nagaraju, 2020), e abordagens específicas baseadas em CNN (Hamed *et al.*, 2023; Joseph *et al.*, 2023; Faye *et al.*, 2023; Shi *et al.*, 2023). A Tabela 1 resume os trabalhos relacionados e seus objetivos.

Na revisão de Bock *et al.* (2020), são destacados os avanços recentes e os desafios no uso do espectro visual e da análise de imagens hiperespectrais para medir a severidade de doenças em plantas. O estudo enfatiza a importância de estimativas e medições precisas e confiáveis, e busca explorar o potencial das medições baseadas em sensores para alcançar esse objetivo. Os autores ressaltam a relevância da quantificação precisa da severidade da doença e sugerem maneiras de aprimorar sua precisão e confiabilidade.

A revisão de Ngugi (2021) mostra os avanços no uso de técnicas de aprendizado profundo para o reconhecimento de doenças em plantas a partir de imagens RGB. Ela enfatiza a mudança para o uso de técnicas de aprendizado profundo em vez de treinar classificadores rasos com características feitas manualmente. O estudo avalia dez modelos de CNN de última geração e identifica modelos adequados para diferentes ambientes computacionais.

Ahmad *et al.* (2023) revisaram 70 estudos sobre o uso de aprendizado profundo para

o diagnóstico de doenças em plantas. A pesquisa abrange requisitos de conjuntos de dados, técnicas de aprendizado profundo e tópicos de pesquisa abertos. Os achados incluem percepções sobre os requisitos de conjuntos de dados, disponibilidade, usabilidade, sensores de imagem e plataformas de coleta de dados, técnicas de aprendizado profundo, generalização de modelos de aprendizado profundo, estimativa da severidade da doença, comparação entre a precisão do aprendizado profundo e a humana, além da identificação de tópicos de pesquisa em aberto.

Nagaraju (2020) apresentam uma revisão sistemática das técnicas de aprendizado profundo para detecção de doenças em plantas. A revisão avalia o estado atual das soluções, incluindo tecnologias e técnicas, abordando desafios em aberto. Os achados destacam diversos modelos de aprendizado profundo empregados na detecção de doenças em culturas. Eles enfatizam a importância do pré-processamento de imagens, incluindo redimensionamento e ajustes de formato, para melhorar a consistência do conjunto de dados e a extração de características.

Shi *et al.* (2023) analisaram 16 artigos de pesquisa que utilizaram CNNs para avaliar a severidade de doenças em plantas. O artigo fornece uma visão geral atualizada dos últimos desenvolvimentos nesta área, incluindo os desafios, o estado atual da pesquisa e possíveis direções futuras. A revisão identificou várias questões não resolvidas na avaliação automática da severidade das doenças em plantas.

Tabela 1 – Resumo das revisões analisadas.

Referência	Foco da Pesquisa
(Bock <i>et al.</i> , 2020)	Avaliar o status atual e o potencial do espectro visível, hiperespectral e multiespectral, e a análise de imagens baseada em sensores CNN para medir com precisão a severidade de doenças em plantas sob condições de campo.
(Nagaraju, 2020)	Visão geral dos estudos recentes sobre o reconhecimento de pragas e doenças em culturas utilizando técnicas de processamento de imagens e aprendizado de máquina.
(Jackulin <i>et al.</i> , 2022; Ahmad <i>et al.</i> , 2023; Patil <i>et al.</i> , 2022; Nagaraju, 2020)	Revisão das várias técnicas e abordagens utilizadas para detectar doenças em plantas utilizando aprendizado de máquina e aprendizado profundo.
(Suganya <i>et al.</i> , 2022)	Visão geral do potencial das técnicas de aprendizado profundo para detecção precoce e classificação de doenças em plantas e distúrbios abióticos.
(Hamed <i>et al.</i> , 2023; Joseph <i>et al.</i> , 2023)	Exame das diversas técnicas e abordagens empregadas na detecção de doenças em plantas através de metodologias baseadas em CNN.
(Faye <i>et al.</i> , 2023)	Revisão dos estudos que determinaram a severidade de plantas utilizando Técnicas de Processamento de Imagens (IPT), Aprendizado de Máquina (ML) clássico e algoritmos de Aprendizado Profundo (DL).
(Shi <i>et al.</i> , 2023)	Revisão dos estudos que determinaram a severidade de plantas utilizando metodologias baseadas em CNN.

2.1 Necessidade de uma revisão


O potencial das CNNs na detecção de doenças e avaliação da severidade é vasto. Enquanto a maioria das outras revisões cobre de forma ampla as diferentes aplicações tecnológicas, focando na detecção de doenças, nosso objetivo é aprofundar-se mais no uso de CNNs para determinar a severidade de doenças em plantas, trabalhando em uma exploração detalhada das pesquisas recentes para destacar novos métodos, modificações e soluções.

Durante nossa revisão dos trabalhos relacionados, identificamos uma revisão sobre o uso de CNNs para avaliação de severidade em plantas (Shi *et al.*, 2023). Reconhecendo a natureza dinâmica deste campo, defendemos que uma pesquisa mais abrangente é necessária para englobar uma gama mais ampla de artigos e métodos, a fim de capturar os avanços e transformações recentes na área.

3 Redes Neurais Convolucionais

As CNNs são arquiteturas de aprendizado profundo projetadas especificamente para processar dados estruturados em matrizes, especialmente para tarefas de visão computacional (Bisong, 2019). Elas consistem em várias camadas, incluindo camadas convolucionais, de pooling e totalmente conectadas, que aprendem automaticamente características hierárquicas das imagens de entrada (Yamashita *et al.*, 2018; Albawi *et al.*, 2017). A estrutura geral de uma CNN é ilustrada na Figura 5.

Figura 5 – Estrutura geral de uma CNN.



O processo começa com a camada de entrada, que representa uma imagem como um array multidimensional. A primeira operação aplicada a essa entrada é a convolução, que envolve deslizar uma pequena matriz conhecida como kernel ou filtro sobre a imagem de entrada. Esse kernel realiza multiplicação elemento por elemento e soma com os pixels dentro de seu campo receptivo, gerando um mapa de características que destaca características locais específicas, como bordas ou texturas (Mairal *et al.*, 2014). A operação matemática da convolução pode ser expressa da seguinte forma: se $I(x, y)$ representa o

valor do pixel na posição (x, y) na imagem de entrada, e $K(i, j)$ representa o kernel, a convolução na posição (p, q) no mapa de características F é dada por:

$$F(p, q) = \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} I(p+i, q+j) \times K(i, j) \quad (1)$$

Onde m e n são as dimensões do kernel. Após a convolução, o mapa de características é passado por uma função de ativação não linear, tipicamente a Unidade Linear Retificada (ReLU), definida como:

$$\text{ReLU}(x) = \max(0, x) \quad (2)$$

A função ReLU introduz não linearidade no modelo, permitindo que ele capture padrões complexos nos dados (Nair *et al.*, 2010).

O kernel detecta padrões específicos na imagem de entrada. Diferentes kernels são aprendidos durante o processo de treinamento por meio da retropropagação, permitindo que a CNN adapte seus filtros às características dos dados de treinamento (Purwono *et al.*, 2023). Esses kernels aprendidos tornam-se cada vez mais complexos nas camadas mais profundas da rede, capturando características de alto nível, como formas ou objetos.

Após os passos de convolução e não-linearidade, uma camada de pooling é aplicada para reduzir as dimensões espaciais dos mapas de características, diminuindo a complexidade computacional e tornando a rede mais robusta a variações na entrada. O tipo mais comum de pooling é o max pooling, que seleciona o valor máximo dentro de uma pequena região do mapa de características, normalmente reduzindo seu tamanho por um fator de dois (Scherer *et al.*, 2010).

Após várias camadas de convolução e pooling, os mapas de características de alto nível são achatados em um vetor unidimensional e alimentados nas camadas totalmente conectadas. Essas camadas realizam as tarefas finais de classificação ou regressão. Cada neurônio em uma camada totalmente conectada recebe entrada de todos os neurônios na camada anterior, permitindo que a rede combine as características extraídas para fazer previsões (Goodfellow *et al.*, 2016). A camada final normalmente usa uma função softmax para tarefas de classificação, produzindo uma distribuição de probabilidade sobre as possíveis classes. Em contraste, para tarefas de segmentação, a rede pode gerar um mapa de classificação pixel a pixel, indicando a categoria de cada pixel na imagem de entrada (Ronneberger *et al.*, 2015).

3.1 Modelos e treinamento

O sucesso das CNNs depende de como os modelos são projetados e treinados. Esse processo envolve considerações como a escolha entre treinar um modelo do zero ou usar aprendizagem por transferência, além de entender os parâmetros-chave que influenciam o processo de treinamento. Treinar uma CNN do zero envolve a inicialização da rede com

pesos aleatórios e o aprendizado de todos os parâmetros do modelo exclusivamente a partir dos dados de treinamento. Essa abordagem é geralmente utilizada quando um grande conjunto de dados diversificado está disponível e a tarefa-alvo difere significativamente das tarefas existentes (Zhao, K. *et al.*, 2020).

A aprendizagem por transferência é uma abordagem alternativa, na qual um modelo CNN pré-treinado, geralmente treinado em um grande conjunto de dados como o ImageNet (Krizhevsky *et al.*, 2012), é ajustado em um conjunto de dados menor e específico para a tarefa. Essa abordagem aproveita as características gerais aprendidas pelo modelo pré-treinado, que podem ser adaptadas à nova tarefa com relativamente poucos dados de treinamento (Yosinski *et al.*, 2014).

Diversos fatores influenciam a eficácia do treinamento das CNNs, como a escolha entre treinar o modelo do zero ou ajustá-lo utilizando aprendizagem por transferência.

Tamanho e Qualidade do Conjunto de Dados: A quantidade e qualidade dos dados de treinamento são cruciais. Conjuntos de dados grandes, com imagens diversificadas e corretamente rotuladas, ajudam o modelo a generalizar melhor para dados novos. Técnicas de aumento de dados, como rotação, redimensionamento e espelhamento, podem aumentar artificialmente o tamanho e a diversidade do conjunto de dados, mitigando o sobreajuste (Shorten *et al.*, 2019).

Taxa de Aprendizado: A taxa de aprendizado controla a rapidez com que o modelo atualiza seus pesos durante o treinamento. Uma taxa de aprendizado muito alta pode fazer com que o modelo convirja rapidamente para uma solução subótima (Konar *et al.*, 2020), enquanto uma taxa muito baixa pode levar a uma convergência lenta ou ao aprisionamento em mínimos locais (Lyu *et al.*, 2022). Técnicas de taxa de aprendizado adaptativa, como o uso de agendamentos de taxa de aprendizado ou otimizadores como o Adam (Kingma *et al.*, 2014), podem ajudar a alcançar um bom equilíbrio.

Tamanho do Lote: O tamanho do lote (*batch*) determina o número de exemplos de treinamento usados em uma iteração de atualização dos pesos do modelo. Lotes menores oferecem atualizações mais frequentes, mas com estimativas de gradiente mais ruidosas, enquanto lotes maiores fornecem atualizações mais estáveis à custa da eficiência computacional. Encontrar um tamanho de lote ótimo é fundamental para um treinamento eficiente (Masters *et al.*, 2018).

Técnicas de Regularização: Métodos de regularização, como regularização L2, dropout e parada antecipada, evitam o sobreajuste (*overfitting*), especialmente quando os dados de treinamento são limitados. O dropout, por exemplo, define aleatoriamente uma fração dos neurônios como zero durante o treinamento, forçando o modelo a aprender características mais robustas (Srivastava *et al.*, 2014).

Função de Perda: A função de perda (*loss function*) mede a discrepância entre as previsões


do modelo e os rótulos reais. A perda de entropia cruzada é comumente utilizada para tarefas de classificação, enquanto o Erro Quadrático Médio (EQM) é típico para tarefas de regressão. Selecionar uma função de perda apropriada é crucial para orientar o processo de aprendizado do modelo (Noel *et al.*, 2023).

Arquitetura do Modelo: A escolha da arquitetura da CNN, incluindo o número de camadas, parâmetros treináveis e configurações das camadas, impacta significativamente o desempenho da CNN (Lucero; Qu, 2017). O design cuidadoso das arquiteturas das CNNs pode melhorar a capacidade de aprender características complexas e melhorar a precisão de classificação (Irvine; Israel, 2022). Modelos mais profundos, como o ResNet, que introduzem conexões residuais para prevenir o problema dos gradientes que desaparecem, possibilitam o aprendizado de características mais complexas, mas exigem ajuste cuidadoso para evitar o sobreajuste e garantir treinamento estável (He; Zhang *et al.*, 2016). Da mesma forma, arquiteturas como o DenseNet, que conectam cada camada a todas as outras, promovem o reaproveitamento de características e mitigam o problema dos gradientes que desaparecem, potencialmente levando a um desempenho melhor em determinadas tarefas (Huang *et al.*, 2017). Além disso, modelos como o VGG, conhecidos pela sua simplicidade e profundidade, são frequentemente usados como referência, apesar de seu maior custo computacional devido ao grande número de parâmetros (Simonyan *et al.*, 2014). O EfficientNet, que escala as dimensões do modelo de forma sistemática, oferece uma abordagem mais equilibrada ao otimizar precisão e eficiência, tornando-o adequado para tarefas com recursos computacionais limitados (Tan; Le, 2019).

4 Método de Pesquisa

A metodologia seguirá o protocolo desenvolvido por Keele *et al.* (2007), que fornece uma abordagem sistemática para garantir rigor e consistência nas revisões de literatura. Esse protocolo é particularmente valioso em áreas como engenharia de software e áreas relacionadas, permitindo que os pesquisadores resumam pesquisas existentes, identifiquem lacunas no conhecimento e forneçam orientações baseadas em evidências para a prática e futuros estudos. A metodologia se caracteriza por sua abordagem estruturada, transparente e reproduzível, enfatizando uma cobertura abrangente, avaliação de qualidade e relatórios detalhados. O processo é organizado em três etapas bem definidas: (1) Planejamento da revisão, (2) Condução da revisão e (3) Relato da revisão. O procedimento metodológico específico aplicado neste trabalho é ilustrado na Figura 6.

Figura 6 – Diagrama detalhado do protocolo de revisão.



Seguindo a necessidade de uma revisão delineada na Seção 2.1, a etapa de planejamento começa com a definição dos objetivos da revisão, seguida pela especificação das questões de pesquisa (RQs). Uma vez que as RQs são definidas, o processo avança para a etapa de condução, onde os critérios de busca são desenvolvidos, incluindo a seleção de palavras-chave relevantes, como "CNN" e "severidade de doenças em plantas", para construir as strings de busca finais. Bancos de dados de alta qualidade, como IEEE, Scopus e Web of Science, foram escolhidos para a busca na literatura. A partir dos retornos da base de dados, a etapa de triagem começa com a remoção de duplicatas, seguida pela triagem de títulos e resumos e aplicação dos critérios de inclusão e exclusão. Os artigos restantes passam pela triagem do texto completo e avaliação de qualidade antes de avançar para a fase de extração de dados. Finalmente, na etapa de relato, os resultados da revisão são apresentados, começando com uma visão geral dos resultados, seguida pelas respostas específicas às RQs. O processo é concluído com as considerações finais.

4.1 Planejamento da revisão

4.1.1 Objetivos da revisão e questões de pesquisa

Avanços recentes em CNNs melhoraram significativamente o desempenho e a aplicabilidade dos modelos para a avaliação da severidade de doenças em plantas (Mudgil *et al.*, 2022). Esses avanços incluem aprendizado por transferência, aumento de dados, arquiteturas leves e mecanismos de atenção, entre outros, para melhorar a precisão, a eficiência do treinamento, o tempo de inferência e outras métricas essenciais (Han, 2018; Kalouris, 2019; Wang, K. *et al.*, 2019). Esta revisão sistemática tem como objetivo analisar as pesquisas mais recentes sobre técnicas de CNN para avaliar a severidade de doenças em plantas, com foco particular em doenças que afetam as folhas, a fim de entender de forma abrangente sua eficácia e orientar as direções e aplicações futuras da pesquisa.

Nosso objetivo é cobrir e explicar (i) O método de aquisição do conjunto de dados (*dataset*) (se coletado de forma autônoma ou obtido de um banco de dados), sua fonte e tamanho, e as culturas e doenças estudadas; (ii) As métricas usadas para avaliação do modelo e seus respectivos resultados; (iii) A arquitetura, *backbone*, método geral, parâmetros de treinamento e novas abordagens empregadas nos modelos de CNN; (iv) Os desafios encontrados durante a pesquisa; (v) As sugestões e lacunas identificadas para trabalhos futuros. Com base nessas considerações, formulamos as seguintes questões de pesquisa:

Q1: Como os datasets foram montados para o treinamento do modelo?

Q2: Quais métricas foram aplicadas para avaliar os modelos de CNN?

Q3: Como os avanços recentes em métodos de CNN, parâmetros de treinamento e arquiteturas foram aplicados pelos pesquisadores para avaliar a severidade de doenças em plantas, e quais foram suas descobertas principais?

Q4: Quais foram as dificuldades no desenvolvimento da pesquisa?

Q5: Quais são as sugestões para trabalhos futuros?

4.2 Condução da revisão

4.2.1 Critérios de Busca

A Tabela 2 descreve os critérios de busca. As buscas foram realizadas em 15 de janeiro e 13 de agosto de 2024, em seis bases de dados (ACM, IEEE Access, Scopus, ScienceDirect, SpringerLink e Web of Science), escolhidas por sua cobertura abrangente, indexação de alta qualidade e relevância para ciência da computação, engenharia e ciências aplicadas. Para garantir uma cobertura completa, também incluímos artigos das 10 principais conferências em visão computacional e reconhecimento de padrões, classificadas pelo índice h5 do Google Scholar em 12 de agosto de 2024: CVPR, ICCV, European Conference on Computer

Vision, IEEE Transactions on Image Processing, IEEE Transactions on Pattern Analysis and Machine Intelligence, ICPR, CVPRW, WACV, ICIP e ICCVW.¹

Dado o recente desenvolvimento das aplicações de CNN para determinar a severidade de doenças em plantas e a rápida evolução desses métodos, buscamos artigos publicados entre 1º de janeiro de 2019 e 31 de julho de 2024, cobrindo os últimos cinco anos e meio. Filtros foram aplicados para recuperar artigos em inglês nas áreas de Ciência da Computação, Ciências Ambientais, Engenharia, Agricultura e Ciências Biológicas, utilizando as expressões de busca ("convolutional neural networks"OR "CNN") AND ("plant disease severity"OR "leaf disease severity").

Tabela 2 – Critérios de Busca.

Aspecto	Descrição
Data da Busca	15 de janeiro e 13 de agosto de 2024
Período	01 de janeiro de 2019 - 30 de julho de 2024
Bases de Dados	ACM, IEEE Access, Scopus, Science Direct, Springer Link, Web of Science, e conferências listadas
Expressão de Busca	("convolutional neural networks"OR "CNN") AND ("plant disease severity"OR "leaf disease severity")
Filtros de Busca	Idioma: Inglês; Área: Ciência da Computação, Ciências Ambientais, Engenharia, Agricultura e Ciências Biológicas; Ano de Publicação: 2019-2023

4.2.2 Critérios de Inclusão e Exclusão

Critérios específicos de inclusão e exclusão foram estabelecidos após a recuperação inicial dos estudos para garantir uma revisão focada e relevante. Esses critérios foram elaborados para filtrar efetivamente a literatura e incluir apenas pesquisas pertinentes. Fontes secundárias, como revisões de literatura, foram excluídas para manter o foco em estudos originais que aplicam diretamente modelos CNN para avaliar a severidade de doenças em plantas. Além disso, estudos que não determinaram a severidade da doença ou que empregaram métodos diferentes das CNNs como técnicas tradicionais de aprendizado de máquina (por exemplo, máquinas de vetores de suporte, árvores de decisão) ou análise manual de imagens foram excluídos para garantir um foco claro nas abordagens baseadas em CNN. Os critérios de inclusão e exclusão são os seguintes:

Critérios de Inclusão: (i) Estudos que empregaram modelos CNN para determinar a severidade de doenças em plantas em sua metodologia; (ii) Artigos publicados em periódicos e conferências listadas.


¹ CVPR: Conference on Computer Vision and Pattern Recognition; ICCV: International Conference on Computer Vision; ICPR: International Conference on Pattern Recognition; CVPRW: Computer Society Conference on Computer Vision and Pattern Recognition Workshops; WACV: Winter Conference on Applications of Computer Vision; ICIP: International Conference on Image Processing; ICCVW: International Conference on Computer Vision Workshops.

Cr terios de Exclus o: (i) Revis es de literatura; (ii) Artigos que n o determinaram a severidade em plantas; (iii) Estudos que determinam a severidade utilizando outros m todos.

4.2.3 Busca e Sele  o dos Estudos

A busca inicial nas bases de dados gerou 250 artigos. Ap s a remo  o de duplicatas, restaram 161 estudos. Esses estudos seguiram para a fase de triagem, que envolveu a leitura dos resumos e a aplica  o dos crit rios de inclus o e exclus o. Durante essa fase, 97 artigos foram removidos, com aproximadamente 70% exclu dos devido aos crit rios (ii) e (iii) e o restante devido ao crit rio (ii) e artigos de acesso restrito. No final, 64 artigos avan aram para a fase de extra  o de dados. As buscas realizadas nas bases de dados das confer ncias listadas n o resultaram em artigos alinhados com o escopo desta revis o. A Figura 7 mostra os detalhes.

Figura 7 – Vis o geral da fase de busca e sele  o dos estudos.



4.2.4 Extra  o e S ntese de Dados

Durante o processo de extra  o de dados, focamos em abordar as quest es de pesquisa. Analisamos os artigos e extra mos as seguintes informa  es: (i) data de revis o; (ii) t tulo; (iii) autores; (iv) refer ncia; (v) banco de dados; (vi) m todo geral utilizado; (vii) planta(s) e doen a(s) abordadas; (viii) aspectos inovadores; (ix) arquiteturas e backbones empregados; (x) montagem do dataset; (xi) m tricas e seus respectivos resultados; (xii) limita  es; (xiii) trabalhos futuros. Utilizamos o software Parsifal (dispon vel em <https://parsifal.org>)

e o Microsoft Excel para organizar e tabular os dados extraídos. Para um resumo das informações chave extraídas, consulte a Tabela 5.

4.2.5 Avaliação de Qualidade

Para avaliar a qualidade dos artigos incluídos, utilizamos uma abordagem adaptada de Guyatt e Rennie (2003). A avaliação da qualidade foi baseada em questões que abordam aspectos gerais do trabalho (Tabela 3). Os critérios de avaliação de qualidade escolhidos (C1 a C5) garantem coletivamente uma avaliação minuciosa do artigo de pesquisa avaliado, abordando seus objetivos fundamentais, relevância contextual, rigor metodológico, contribuições inovadoras e clareza dos achados. Aplicamos essas questões a cada artigo e fornecemos respostas com pontuações correspondentes variando de 0 (fraco), 0.5 (médio) a 1 (forte).

Tabela 3 – Critérios de qualidade.

Critério	Resposta
C1. O objetivo da pesquisa está bem definido?	(1) Forte; (0.5) Médio; (0) Fraco
C2. O contexto da pesquisa está bem abordado?	(1) Forte; (0.5) Médio; (0) Fraco
C3. A metodologia da pesquisa fornece um contexto adequado para alcançar o objetivo da pesquisa?	(1) Forte; (0.5) Médio; (0) Fraco
C4. O estudo introduz abordagens inovadoras ou camadas adicionais em comparação com métodos tradicionais de CNN?	(1) Forte; (0.5) Médio; (0) Fraco
C5. Os achados estão claramente definidos?	(1) Forte; (0.5) Médio; (0) Fraco

O primeiro critério (C1) avaliou a clareza e precisão do objetivo do estudo, examinando se foi explicitamente declarado e forneceu uma direção clara e abrangente. O segundo critério (C2) examinou a contextualização, avaliando a presença de uma seção de antecedentes, detalhes sobre a planta e a doença estudada, e os benefícios práticos delineados no artigo. O terceiro critério (C3) foca na metodologia da pesquisa. Ele examina se o método oferece uma estrutura robusta para alcançar o objetivo declarado da pesquisa, envolvendo a avaliação do rigor, adequação e coerência da metodologia em relação aos objetivos da pesquisa. Considera-se fatores como o desenho experimental, métodos de coleta de dados e análises estatísticas para garantir a confiabilidade e validade do estudo. O quarto critério (C4) mensura o nível de inovação nas técnicas empregadas, considerando a incorporação de novas abordagens e modificações em comparação com métodos convencionais de CNN. Por fim, o quinto critério (C5) focou nos achados do estudo, avaliando a organização dos resultados, as métricas empregadas e a comparação feita com outros estudos relevantes.

Além desses critérios, coletamos o quartil, o índice-H (*H-index*) e o índice *SCImago* para cada periódico para verificar o fator de impacto. O quartil é um sistema de classificação que divide os periódicos dentro de um campo específico em quatro quartis (Q1, Q2, Q3,

Q4) com base em seu fator de impacto, sendo o Q1 o top 25% dos periódicos. O índice H é uma métrica que mede a produtividade e o impacto das citações de um periódico ou pesquisador, indicando quantos artigos (h) foram citados pelo menos h vezes. O índice *SCImago* reflete o prestígio do periódico, calculado considerando o número de citações recebidas pelos artigos de um periódico e a importância das fontes citantes. Os índices foram obtidos em 12 de agosto de 2024, no site SJR - Scimago Journal & Country Rank (<https://www.scimagojr.com/>). O índice H e o *SCImago* foram normalizados com base nos valores máximos obtidos na nossa amostra (2,07 e 315, respectivamente). Esses índices normalizados, Índice H_{norm} e $SCImago_{norm}$, foram incorporados ao processo de pontuação final. A pontuação final de cada artigo, variando de 0 a 1, foi determinada pela média dos índices normalizados e pela avaliação dos critérios de qualidade, conforme representado pela seguinte equação:

$$\text{Pontuação Final} = \frac{C1 + C2 + C3 + C4 + C5 + \text{Índice } H_{norm} + SCImago_{norm}}{7} \quad (3)$$

A pontuação final da avaliação de qualidade foi então categorizada nos seguintes intervalos: "Ruim"(0 - 0.20), "Regular"(0.21 - 0.45), "Boa"(0.46 - 0.65), "Muito Boa"(0.66 - 0.85) e "Excelente"(0.86 - 1.00).

Para maior clareza e com base nos dados avaliados, a Tabela 4 ilustra exemplos da avaliação de qualidade de 5 artigos com pontuações finais cobrindo todos os intervalos.

Tabela 4 – Exemplos de pontuações da avaliação de qualidade.

Artigo	C1	C2	C3	C4	C5	Índice H_{norm}	$SCImago_{norm}$	Pontuação final	Intervalo
A	0.5	0	0	0.5	0	0.15 (48)	0.20 (0.41)	0.19	Ruim
B	0.5	0.5	0	0.5	0.5	0.17 (53)	0.28 (0.57)	0.35	Regular
C	0.5	0.5	0.5	0.5	0.5	0.47 (149)	0.77 (1.59)	0.53	Boa
D	0.5	1	0.5	1	1	0.48 (152)	0.40 (0.82)	0.70	Muito Boa
E	1	1	1	1	1	0.79 (250)	1.00 (2.07)	0.97	Excelente

Nota: Os valores entre parênteses são valores reais, não normalizados.

A pontuação final incorpora o desempenho do artigo nos critérios de avaliação e nos índices (índice H e índice *SCImago*). Por exemplo, o Artigo "A", com uma pontuação final de 0.19, reflete um desempenho fraco em relação às questões de pesquisa, metodologia e clareza dos achados, além de índices de citação baixos.

O Artigo "C", com uma pontuação final de 0.53, se classifica na categoria "Boa". Essa pontuação indica que, embora o Artigo "C" apresente um desempenho valioso nos critérios avaliados, ele não alcança os níveis mais altos observados nos Artigos "D" e "E". Seus índices de citação e impacto geral são respeitáveis, mas não tão altos quanto os dos artigos classificados como "Muito Boa" ou "Excelente".

Por outro lado, com uma pontuação final de 0.97, o Artigo "E" combina excelentes avaliações na condução da pesquisa e nas métricas de citação, alcançando uma classificação de "Excelente". Essa alta pontuação reflete uma qualidade e impacto excepcionais, destacando que ele se sobressai tanto nos aspectos qualitativos da pesquisa quanto no reconhecimento mais amplo.


5 Resultados da revisão

5.1 Visão geral

Ao analisar os 64 artigos que prosseguiram para a extração de dados, os resultados na Figura 8 revelam uma tendência clara no volume de estudos publicados ao longo do período de pesquisa. Houve uma escalada notável, com o número de artigos aumentando de 3 em 2019 para 17 em 2023. Os dados de 2024 reforçam ainda mais essa tendência, com 12 artigos publicados até 30 de julho.

O aumento do uso de CNNs na detecção de doenças de plantas e na avaliação da severidade pode ser atribuído a vários fatores. Avanços rápidos em técnicas de aprendizado profundo permitiram que os pesquisadores desenvolvessem modelos CNN mais eficientes para avaliar diversas doenças de plantas. A crescente disponibilidade de grandes conjuntos de dados e as melhorias nos *frameworks* também contribuíram para a expansão recente das aplicações de CNN na agricultura (Shrestha *et al.*, 2020; Mudgil *et al.*, 2022). Além disso, a integração das CNNs com *hardware* de baixo custo e *smartphones* tornou a detecção e avaliação de doenças em tempo real mais acessível, impulsionando ainda mais a pesquisa nesta área (Bhargav; Pathak, 2023).

Figura 8 – Distribuição do número de publicações sobre avaliação da severidade de doenças de plantas usando CNNs. *Dados de 2024 até 30 de julho.



Em relação às culturas e doenças estudadas, destacam-se o tomate, trigo e arroz, com 10, 9 e 7 estudos, respectivamente. As doenças fúngicas e bacterianas têm sido o foco principal, particularmente "murcha precoce" e "murcha tardia" em tomates, "doença da

brusone" e "murcha bacteriana" em arroz, e "ferrugem amarela" no trigo. A pesquisa sobre essas três culturas representa 42% de todos os estudos nesta revisão.

Arroz, trigo e tomate são culturas de importância global, essenciais para a segurança alimentar e crescimento econômico (Wiebe *et al.*, 2020). O foco nos estudos modernos de avaliação de severidade dessas culturas e suas doenças associadas parece estar diretamente relacionado à sua importância e aos impactos negativos significativos sobre a produtividade.

Murcha precoce (*Alternaria solani*) e tardia (*Phytophthora infestans*) são doenças importantes que afetam os tomates. A murcha precoce pode reduzir a produção de tomates em até 78% (Chothani *et al.*, 2017), levando a perdas significativas, com reduções de produtividade variando de 0,75 a 0,77 t/ha para cada aumento de 1% na severidade da doença (Saha; Das, 2012; Fontem, 2003; Foolad *et al.*, 2008).


No arroz, a murcha bacteriana, causada por *Xanthomonas oryzae* pv. *oryzae*, pode reduzir a produção de 20 a 50% (Sattari *et al.*, 2014; Shekhar *et al.*, 2020). Já a brusone do arroz, causada por *Magnaporthe oryzae*, pode levar a perdas de 60 a 100%, impactando significativamente a qualidade do grão, a taxa de arroz integral e a palatabilidade (Noh *et al.*, 2007; Kihoro *et al.*, 2013).

A ferrugem amarela, causada por *Puccinia striiformis* f. sp. *tritici*, ameaça significativamente a produção mundial de trigo, causando grandes perdas de produtividade e afetando a qualidade do grão. Estudos mostram reduções de produtividade variando de 3,5 a 35% (Al-Maaroof, 2019) até 4.700 kg/ha (Carmona *et al.*, 2019). Essa doença afeta negativamente o peso do grão, o número de grãos por espiga, o teor de proteína e de glúten (Al-Maaroof, 2019; Kebede *et al.*, 2024; Mabrouk *et al.*, 2022). Para uma lista detalhada de culturas e doenças, veja a Tabela 5.

Os periódicos que lideram a frequência de publicações são "Computers and Electronics in Agriculture", "Frontiers in Plant Science" e "IEEE Access", com 7, 6 e 4 publicações, respectivamente. (Esgario *et al.*, 2020), (Lin *et al.*, 2019) e (Liang *et al.*, 2019) são os artigos com mais citações. No ranking de citações por país, a China lidera, seguida por Índia e Estados Unidos.

Em relação à avaliação da qualidade, 65% dos artigos analisados provêm de periódicos com classificação no quartil Q1. A Figura 9 mostra a distribuição final das faixas em porcentagem. Notavelmente, artigos com índices finais avaliados como 'muito bons' e 'excelentes' representam 74% dos artigos avaliados. Isso indica que a maioria dos artigos analisados demonstra rigor metodológico, abordagens inovadoras, achados claros e índices de alto impacto. Isso reforça o alto valor desta revisão, pois inclui predominantemente pesquisas de alta qualidade que provavelmente contribuirão para o campo e influenciarão significativamente as pesquisas futuras.

Figura 9 – Distribuição de Qualidade dos Artigos.



5.2 Abordagens gerais para avaliação da severidade de doenças de plantas usando CNN

De maneira geral, a avaliação da severidade de doenças de plantas utilizando CNN envolve três etapas principais: (i) aquisição e pré-processamento de dados, (ii) arquitetura da CNN e treinamento do modelo, e (iii) avaliação de desempenho do modelo.


As fases iniciais da pesquisa normalmente envolvem a coleta e o pré-processamento dos conjuntos de dados. O pré-processamento inclui filtros para reduzir o ruído e melhorar o contraste, o brilho e a nitidez. O objetivo é corrigir falhas nas imagens e destacar as áreas danificadas. Em seguida, alguns pesquisadores incorporam o processo de aumento de dados para expandir o conjunto de dados. Esse processo pega as imagens originais e introduz diversas modificações, como rotações, desfoques e ruídos, ampliando o conjunto de dados de treinamento. Essa estratégia de aumento fortalece a robustez do conjunto de dados, expondo o modelo a variações e diferentes cenários durante o treinamento. No final, essa abordagem melhora a capacidade de generalização do modelo, permitindo que ele tenha um bom desempenho em dados não vistos (Shorten *et al.*, 2019). Em seguida, é necessário dividir o conjunto de dados em conjuntos de treinamento, validação e teste. Durante a fase de treinamento, o modelo aprende utilizando o conjunto de dados de treinamento, que fornece exemplos rotulados para o processo de aprendizado. Simultaneamente, o conjunto de dados de validação avalia independentemente o desempenho do modelo, ajudando a ajustar os parâmetros e prevenindo o *overfitting* (Domingos, 2012). Após a fase de treinamento, o modelo classifica as imagens do conjunto de dados de teste, obtendo as classificações de severidade. Finalmente, métricas de avaliação são utilizadas para avaliar o desempenho do modelo proposto.

Nossos achados mostram que os estudos se dividem em dois grupos principais: modelos baseados em CNN para classificação e segmentação.

Modelos baseados em CNN para classificação: A Figura 10 ilustra esse cenário. Após a montagem do conjunto de dados, as imagens passam pelo processo de rotulagem, onde especialistas classificam a severidade das folhas em diferentes graus de afecção (por exemplo, saudável, leve, moderado, severo). As imagens rotuladas dos conjuntos de dados


de treinamento e validação são utilizadas para treinar o modelo. Após o treinamento, o modelo pode inferir e classificar o estado de saúde da folha em análise.

Figura 10 – Abordagem baseada em CNN para classificação.



Modelos baseados em CNN para segmentação: Como mostrado na Figura 11, o modelo distingue os pixels que correspondem a lesões daqueles que não correspondem. Após a montagem do conjunto de dados, todas as imagens passam pelo processo de rotulagem. Nesse processo, as imagens das plantas são anotadas manualmente para destacar e identificar as regiões de interesse. A precisão e a qualidade do conjunto de dados rotulados são cruciais para a eficácia do modelo treinado (Toda; Okura, 2019). Softwares especializados como Labelbox (<https://labelbox.com>), VGG Image Annotator (VIA) (Dutta; Zisserman, 2019), e COCO Annotator (Brooks, 2019) são frequentemente usados para permitir que os anotadores marquem e categorizem áreas relevantes nas imagens. Essas informações, transcritas em coordenadas de posição, são usadas no treinamento. Após o treinamento, o modelo pode realizar inferências e retornar as máscaras correspondentes às lesões detectadas, possibilitando calcular a severidade em termos percentuais.


Figura 11 – Abordagem baseada em CNN para segmentação.



Foi observado um equilíbrio na escolha dessas duas abordagens, com 34 estudos optando por modelos baseados em CNN para segmentação e 30 para classificação. As respostas à questão de pesquisa 3 (RQ3) fornecem informações adicionais sobre os métodos empregados e seus respectivos modelos.

Modelos baseados em CNN para classificação e segmentação têm vantagens e desvantagens distintas na detecção da severidade de doenças em plantas. Modelos de classificação oferecem interpretabilidade ao associar diretamente a saída com classes de severidade predefinidas, simplificando o processo de anotação ao categorizar as folhas em classes predeterminadas. No entanto, podem carecer de precisão na localização das lesões e ter dificuldades com lesões sobrepostas (Shoaib *et al.*, 2022). Em contrapartida, os modelos de segmentação fornecem informações precisas de localização e lidam de forma eficaz com sobreposições, permitindo uma determinação precisa da severidade em termos percentuais para uma avaliação detalhada da extensão dos danos (Wang, H. *et al.*, 2023). No entanto, a anotação desses modelos é mais complexa, exigindo identificação precisa das regiões de interesse. Além disso, esses modelos são computacionalmente mais complexos, necessitando de tempos de treinamento mais longos e recursos computacionais aumentados (Ronneberger *et al.*, 2015). A escolha das abordagens deve pesar cuidadosamente a interpretabilidade, a complexidade da anotação e as demandas computacionais. A Figura 12 apresenta um resumo das etapas comuns.

Figura 12 – Sequência comum de eventos para determinação da severidade usando CNNs.



5.3 RQ1: Como os datasets foram montados para o treinamento do modelo?

As imagens para a montagem dos datasets foram obtidas a partir de fontes de coleta própria e bancos de dados online. Foram utilizadas imagens de ambientes naturais e controlados. Um plano de fundo homogêneo com equilíbrio de luz controlado é normalmente aplicado nas imagens em ambientes controlados. Essa abordagem visa evitar desafios na distinção da folha-alvo de outros objetos em um ambiente natural e impedir que diferenças de luminosidade prejudiquem a visualização das lesões. No entanto, como veremos, essa aplicação pode limitar o uso do modelo em situações da vida real.

Observou-se que 63,3% dos estudos utilizaram imagens coletadas pelo próprio pesquisador, 26,5% utilizaram bancos de dados online e 4% optaram por conjuntos de dados mistos usando ambas as fontes. Três estudos não especificaram a origem do conjunto de dados. Entre os que utilizaram bancos de dados online, 77% escolheram o PlantVillage (<https://plantvillage.psu.edu/>). CroudAI (<https://www.crowdai.com/>), Kaggle (<https://www.kaggle.com/>), AIChallenger (<https://github.com/AIChallenger/>) e PlantDoc (<https://github.com/pratikkayal/PlantDoc-Dataset>) também se destacaram como fontes de imagens.

O conjunto de dados do PlantVillage é um recurso valioso em fitopatologia, contendo mais de 54.000 imagens de alta resolução que representam várias doenças de plantas, pragas e deficiências nutricionais em 14 espécies de culturas. O conjunto de dados é amplamente utilizado para treinar e avaliar modelos de CNN para identificação de doenças em plantas (Verma, 2019; Mohameth *et al.*, 2020).

Apesar de ser uma abordagem trabalhosa, 63,3% dos estudos preferiram imagens coletadas pelos próprios pesquisadores para a criação dos datasets. Essa escolha é motivada

pela representação localizada e pelo controle proporcionado, capturando condições e doenças específicas de uma determinada área geográfica. Neste caso, os pesquisadores mantêm controle sobre o processo de coleta, garantindo a qualidade, relevância e diversidade adaptadas às necessidades de sua pesquisa. Além disso, os conjuntos de dados coletados localmente são vantajosos devido às limitações potenciais dos bancos de dados online, que podem não abranger todo o espectro de doenças e espécies vegetais alvo de estudo.

61% dos estudos utilizaram imagens capturadas em ambientes controlados. É essencial reconhecer que modelos treinados exclusivamente com imagens provenientes de ambientes controlados podem apresentar capacidades limitadas de generalização e dificuldade para lidar com as complexidades e variações inerentes às aplicações do mundo real.

5.4 RQ2: Quais métricas foram aplicadas para avaliar os modelos de CNN?

Após a fase de treinamento, o modelo é aplicado ao conjunto de dados de teste para gerar classificações previstas. Os resultados, comparando as classificações previstas com as de referência, são tipicamente ilustrados por meio de uma matriz de confusão, seguida pelo cálculo de métricas como acurácia, precisão, recall e F1-score. Em aplicações baseadas em classificação com CNN, a matriz de confusão contrasta as classificações reais e previstas de severidade. Em modelos de CNN baseados em segmentação, a avaliação envolve análise em nível de pixel e a comparação entre as classificações de severidade previstas e de referência. Além disso, para cenários de segmentação, métricas suplementares como IoU (Intersection over Union ou Índice de Jaccard), MIoU (Mean Intersection over Union) e Dice (coeficiente de Sørensen-Dice) são incorporadas, oferecendo uma avaliação mais abrangente das máscaras previstas.

Sokolova e Lapalme (2009) definem as métricas e como calculá-las da seguinte forma:

Acurácia é uma métrica de desempenho comumente utilizada que mede a correção geral do modelo ao fazer previsões. É a razão entre as amostras previstas corretamente e o número total de amostras no conjunto de dados. *Precisão* é uma medida que indica a proporção de previsões positivas corretas em relação ao total de previsões positivas feitas pelo modelo. É calculada dividindo o número de verdadeiros positivos - *True Positives* (TP) pela soma de verdadeiros positivos e falsos positivos - *False Positives* (FP). *Recall*, ou sensibilidade, é a proporção de lesões verdadeiramente detectadas pelo modelo em relação ao número total de lesões existentes. *F1-score* é uma métrica que combina precisão e recall em uma única medida para fornecer uma visão equilibrada do desempenho do modelo. É a média harmônica entre precisão e recall. Finalmente, *IoU*, *MIoU* e *Dice* avaliam a sobreposição entre o conjunto de pixels segmentados por um modelo (máscara prevista) e o conjunto de pixels reais ou esperados (*ground truth*). Essas métricas são comumente usadas para avaliar o desempenho do modelo em tarefas de segmentação de imagens. As equações são dadas por:

$$\text{Acurácia} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \times 100\% \quad (4)$$

$$\text{Precisão} = \frac{\text{TP}}{\text{TP} + \text{FP}} \times 100\% \quad (5)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \times 100\% \quad (6)$$

$$\text{F1-score} = \frac{2 \times \text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}} \times 100\% \quad (7)$$

$$\text{IoU} = \frac{\text{TP}}{\text{TP} + \text{FP} + \text{FN}} \times 100\% = \frac{\text{Área de sobreposição}}{\text{Área de união}} \quad (8)$$


$$\text{Dice} = \frac{2 \times \text{TP}}{2 \times \text{TP} + \text{FP} + \text{FN}} \times 100\% = \frac{2 \times \text{Área de sobreposição}}{\text{Área total}} \quad (9)$$

$$\text{MIoU} = \frac{1}{N} \sum_{i=1}^N \frac{\text{TP}_i}{\text{TP}_i + \text{FP}_i + \text{FN}_i} = \frac{1}{N} \sum_{i=1}^N \frac{\text{Área de sobreposição}_i}{\text{Área de união}_i} \quad (10)$$

Onde TP é verdadeiro positivo, FP é falso positivo, TN é verdadeiro negativo, FN é falso negativo, e N é o número de classes.

As métricas IoU, MIoU e Dice são inerentes ao processo de segmentação, considerando as áreas de sobreposição, união e total. A Figura 13 fornece uma representação visual dessas áreas com base na máscara de referência da lesão gerada no processo de rotulagem (ground truth) e na máscara da lesão gerada pelo modelo (máscara prevista).

Figura 13 – Uma ilustração da máscara de referência (ground truth), máscara prevista e as respectivas áreas de sobreposição, união e total utilizadas nas métricas IoU, MIoU e Dice.



5.5 RQ3: Quais métodos, parâmetros de treinamento e arquiteturas de CNN foram utilizados por pesquisadores para avaliar a severidade de doenças em plantas, e quais foram seus resultados?

Encontramos diversas propostas e resultados para aplicações de modelos de CNN. Para uma melhor compreensão, os dados da pesquisa serão apresentados em diferentes categorias: *Frameworks* clássicos e *frameworks* aprimorados/híbridos.

5.5.1 *Frameworks* clássicos

Esta seção destaca estudos que aplicaram diretamente modelos de CNN estabelecidos, sem modificações significativas. Estruturas clássicas continuam sendo uma abordagem proeminente em pesquisas recentes que utilizam CNNs para avaliar a severidade de doenças em plantas.

Fernández-Campos *et al.* (2021) exploraram a classificação de doenças em espigas de trigo. O modelo utilizou aprendizado por transferência com base no dataset ImageNet e na arquitetura ResNet101. O estudo alcançou uma acurácia de 94,44% e um F1-score de 94%, categorizando as doenças em saudável, baixa, moderada e alta severidade, com base em um dataset de 1.800 imagens de espigas de trigo coletadas manualmente.

Utilizando algoritmos de segmentação de imagem para estimar a severidade de doenças em um processo de duas etapas, Bo-Yuan Liu *et al.* (2022) aplicaram as arquiteturas DeeplabV3+, PSPNet e UNet. Os modelos foram treinados por 100 épocas, com uma taxa de aprendizado inicial de 0,0001 e um tamanho de batch de 2. O estudo alcançou uma precisão de 95,84%, um recall de 95,54% e um valor de MIOU de 92,05%, com base em um dataset de 5.382 imagens de folhas saudáveis e doentes coletadas manualmente.

No estudo de Lin *et al.* (2019), a arquitetura U-Net foi utilizada para segmentar e quantificar o oídio em plantas de pepino. A severidade foi categorizada em quatro níveis — saudável, leve, moderado e severo — utilizando um dataset de 50 folhas de pepino infectadas coletadas manualmente, com o modelo CNN alcançando uma acurácia de 94,5%. De forma similar, Mathieu *et al.* (2024) empregaram a arquitetura U-Net para focar em trigo infectado com *Septoria tritici blotch* (STB), segmentando e quantificando a necrose. O modelo, treinado com dados coletados manualmente, alcançou taxas de precisão de 95%.

Investigando a estimativa da severidade de doenças no arroz, Patil *et al.* (2022) propuseram um modelo utilizando uma abordagem otimizada baseada em Faster R-CNN para calcular a área de instâncias de folhas e regiões infectadas. O modelo de classificação de arroz com a arquitetura backbone EfficientNet-B0, utilizando uma taxa de aprendizado de 0,0001 e o otimizador Stochastic Gradient Descent (SGD), superou as arquiteturas backbone VGG16, ResNet101 e MobileNet, alcançando uma acurácia de 96,43%.

No estudo de Goncalves *et al.* (2021), a segmentação semântica envolveu o treinamento de seis arquiteturas de Redes Neurais Convolucionais (CNN): Unet, SegNet, PSPNet, FPN

e duas variantes do DeepLabv3+. Os valores de acurácia variaram de 90,4% a 95,6%, e os valores de recuperação variaram de 89,4% a 94,7%. Os maiores e menores valores médios das métricas foram obtidos, respectivamente, com as arquiteturas FPN e DeepLabv3 (MobileNetv2).

5.5.2 *Frameworks* aprimorados e híbridos

Esta seção foca em trabalhos que incorporam ou estenderam camadas de *frameworks* existentes, contribuindo para a evolução e o aprimoramento de metodologias estabelecidas.

Noon *et al.* (2022) introduziram um método para detectar doenças em espigas de trigo, incorporando uma camada de Pooling de Pirâmide Espacial - *Spatial Pyramid Pooling* (SPP) ao modelo YOLOX. O modelo aprimorado, YOLOX-s, alcançou uma precisão média (mAP) de 73,13% em seu conjunto de dados, demonstrando uma melhoria em relação à precisão média do modelo YOLOX original, que foi de 69,90%. A SPP é uma técnica que permite o processamento eficiente de imagens de tamanhos variados, capturando informações contextuais em diferentes escalas espaciais e gerando uma representação fixa e compacta para as camadas subsequentes da rede neural. Isso é feito dividindo a camada final de uma CNN em regiões fixas e aplicando pooling a cada região (He; Zhang *et al.*, 2015).

Yang, Li *et al.* (2024) apresentaram o LDI-NET, um novo framework multi-rótulo composto por três módulos: um tokenizador de características, um codificador de tokens e um decodificador multi-rótulo. Esse framework permite a identificação simultânea do tipo de planta, da doença na folha e da severidade, sem aumentar o número de categorias ou adicionar ramificações. Aprimorado com técnicas avançadas de CNN, a metodologia foi validada no conjunto de dados AI Challenger 2018 para requieima tardia em tomate, composto por 31.718 imagens categorizadas em níveis de severidade leve, moderado e grave. O LDI-NET alcançou 99,42% de acurácia para identificação de planta, 88,55% para classificação de severidade e 87,40% para a acurácia combinada de planta-doença-severidade.

No estudo de Liang *et al.* (2019), foi desenvolvida a arquitetura PD2SE-Net, que combina estruturas residuais e unidades de embaralhamento (*shuffle units*) para atingir seus objetivos. Os melhores resultados foram obtidos utilizando o otimizador Stochastic Gradient Descent (SGD), com acurácias gerais de 91%, 99% e 98% para estimativa de severidade da doença, reconhecimento de espécies de plantas e classificação de doenças em plantas, respectivamente.

Apresentando um modelo híbrido de CNN chamado TomSevNet, Shruthi e Nagaveni (2023) incorporaram resíduos autorregulados e um bloco inception para a classificação da severidade de doenças em plantas. O TomSevNet, projetado com três níveis de severidade

(baixo, médio e alto) e treinado em um conjunto de dados de 15.961 imagens do Plant Village, obteve uma acurácia de teste de 96,91% e um F1-score de 97%.

Vinay Lamba Kukreja *et al.* (2023) empregaram uma abordagem híbrida, combinando uma CNN com uma Máquina de Vetores de Suporte - *Support Vector Machine* (SVM) para desenvolver um método inovador de classificação da severidade da brusone. Este híbrido CNN-SVM alcançou uma acurácia de 97% em quatro categorias de severidade: leve, média, grave e profunda. O conjunto de dados utilizado para treinamento e avaliação foi composto por 1.908 imagens coletadas manualmente.

O modelo Yellow-Rust-Xception, para reconhecer a severidade da ferrugem amarela do trigo, foi desenvolvido por Hayit (2021), utilizando os modelos pré-treinados Xception, MobileNet e ResNet. Um conjunto de dados autocoletado contendo 3.750 imagens foi usado para derivar cinco categorias de severidade. O modelo proposto superou os demais, alcançando uma acurácia de 91,2%.


Um framework de segmentação em duas etapas foi introduzido por Chunshan Wang *et al.* (2021). O framework combina DeepLabV3+ e U-Net para analisar imagens com fundos complexos. O DeepLabV3+ foi utilizado para a segmentação das folhas na etapa inicial, enquanto a etapa subsequente utilizou o U-Net para segmentação de manchas de doenças, facilitando a classificação da severidade da doença. O modelo alcançou uma acurácia geral de 96,5% em um conjunto de dados autocoletado.

Redes neurais leves

Contexto evolutivo: Diversas arquiteturas de redes neurais têm feito contribuições significativas ao enfatizar a eficiência e a otimização, permitindo a criação de modelos leves. O MobileNets (Howard *et al.*, 2017) foi pioneiro na eficiência com convoluções separáveis em profundidade, seguido pelo ShuffleNet (Zhang, X. *et al.*, 2018), que enfatizou o embaralhamento de canais. O SqueezeNet (Iandola *et al.*, 2016) introduziu módulos de "squeeze-and-excitation" e o EfficientNet (Tan; Le, 2019) otimizou os parâmetros da rede.

Introduzido por Sandler *et al.* (2018), o MobileNetV2 incorpora resíduos invertidos e gargalos lineares, contribuindo para maior eficiência e desempenho aprimorado (Figura 14). Os resíduos invertidos envolvem convoluções separáveis em profundidade leves dentro dos blocos residuais, reduzindo os custos computacionais. Os gargalos lineares são empregados para manter o fluxo de informações e facilitar um treinamento mais rápido. O MobileNetV2 equilibra o tamanho do modelo, velocidade e precisão com essas inovações, tornando-o bem adequado para ambientes com restrições de recursos.

Figura 14 – MobileNetV2.



Fonte: Adaptado de (Sandler *et al.*, 2018).

O uso de arquiteturas leves no contexto de detecção de doenças de plantas e avaliação de severidade visa avançar a identificação em tempo real e estimativas de severidade em diversas culturas, particularmente em condições de campo, utilizando dispositivos como plataformas móveis. Pesquisadores estão explorando ativamente modificações em arquiteturas estabelecidas para desenvolver modelos leves e eficientes, facilitando sua implantação em dispositivos móveis para análises rápidas e práticas em ambientes agrícolas dinâmicos.

Visando desenvolver um modelo leve e eficiente para identificar e estimar a severidade de doenças em plantas de pepino, Agarwal *et al.* (2021) modificaram a arquitetura LeNet-5, incorporando um novo modelo Conv2D com uma função de ativação ReLU modificada. O estudo obteve uma precisão de 93,75% na classificação de imagens de folhas de pepino em diferentes categorias de doenças.

O estudo de Weizhen Liu *et al.* (2024) focou na ferrugem do trigo, empregando uma abordagem de segmentação em duas etapas. Inicialmente, o DeepLabV3+ foi usado para segmentação das folhas, seguido pelo U-Net para identificação adicional de lesões e áreas saudáveis. O DeepLabV3+ com Xception foi utilizado para extração de características. O estudo categorizou os resultados da segmentação em três classes e obteve um MIoU de 83,44% para as áreas das lesões da ferrugem do trigo.

Shuo Chen *et al.* (2021) empregaram diversas arquiteturas de CNN, incluindo o MobileNet e o Xception, para segmentação da doença de risco bacteriano das folhas do arroz, reportando uma precisão de severidade de 94%.

Em outro trabalho, Haque *et al.* (2022) propuseram uma estrutura CNN leve para reconhecer os estágios de severidade da doença de mancha foliar de Maydis do milho. A estrutura é aumentada com dois módulos Inception modificados, e obteve uma precisão de classificação de aproximadamente 99,13% nas imagens de teste. Weirong Chen *et al.*

(2022) empregaram o MobOcaNet, uma arquitetura de rede leve baseada no MobileNet-V2, para reconhecer doenças das folhas de batata, alcançando uma precisão de 97,73%.

CNN-LSTM (Long Short-Term Memory CNN)


Contexto da evolução: Modelos CNN-LSTM fazem parte das RNNs (Redes Neurais Recorrentes - *Recurrent Neural Networks*), introduzidas no artigo seminal de Elman (1990) para estender redes neurais tradicionais no processamento de sequências de dados. Ao contrário das redes neurais *feedforward*, as RNNs possuem conexões recorrentes que permitem que a informação seja passada de um passo de tempo para o próximo, proporcionando uma memória limitada (Tixier, 2017). A evolução dos modelos CNN-LSTM avançou significativamente nas tarefas de processamento de imagens e sequências. As CNNs se destacam na extração de características espaciais, enquanto as LSTMs capturam dependências temporais (Patel *et al.*, 2018; Jain *et al.*, 2020).

Abdalla *et al.* (2024) desenvolveram um método combinando CNN com redes Bidirecionais de Long Short-Term Memory (BiLSTM), utilizando imagens de sistemas aéreos não tripulados (UAS) para a avaliação da severidade de doenças. Modelos pré-treinados como VGG, DenseNet, InceptionV3 e ResNet foram usados como backbones para a extração de características. Especificamente, o modelo ResNet101-BiLSTM alcançou a maior precisão geral de 89,7%.

Shweta Lamba *et al.* (2023) propuseram uma arquitetura de classificação de severidade de doenças em 4 níveis para o estudo da doença bacteriana de manchas, que integra CNNs com redes Long Short-Term Memory (LSTM). Esta abordagem híbrida foi aplicada a um conjunto de dados abrangente contendo 1.856 imagens da doença, demonstrando a profundidade da pesquisa. O modelo CNN-LSTM alcançou precisões de classificação de 92%, 88%, 86% e 94% nas quatro classes de severidade, com uma precisão geral de 92%.

Yafei Wang *et al.* (2024) utilizaram uma arquitetura CNN-LSTM para modelar as relações complexas e não lineares entre os fatores ambientais da estufa e a incidência de oídio em pepino. O conjunto de dados incluiu dados ambientais da estufa durante o período de cultivo do pepino, incorporando fatores como temperatura média, umidade, precipitação fora da estufa e contagem de esporos de oídio dentro e fora da estufa. Um total de 10 fatores de entrada foi combinado em um vetor de série temporal e alimentado na CNN, que processou esses fatores através de camadas de convolução e agregação. O modelo CNN-LSTM (Figura 15) alcançou um erro absoluto médio (Mean Absolute Error - MAE) de 0,069, erro quadrático médio (Mean Squared Error - MSE) de 0,0098, raiz do erro quadrático médio (Root Mean Squared Error - RMSE) de 0,0991 e um coeficiente de determinação (R^2 - Coefficient of Determination) de 0,9127. O erro máximo entre os valores previstos e reais foi de 16,9398%.

Figura 15 – Diagrama da estrutura da arquitetura CNN-LSTM utilizada na pesquisa.



Fonte: (Wang, Y. *et al.*, 2024).

Mecanismo de Atenção

Contexto de evolução: O surgimento e a evolução dos mecanismos de atenção nas CNNs marcaram um avanço significativo no aprendizado profundo. Os mecanismos de atenção originaram-se no processamento de linguagem natural, especificamente na tradução automática (Jia, 2019). Bahdanau *et al.* (2014) introduziu o conceito de atenção, visando superar a limitação dos vetores de contexto de tamanho fixo nos modelos tradicionais. Essa ideia foi posteriormente adaptada e aplicada a tarefas de visão computacional, incluindo reconhecimento de imagens e detecção de objetos, contribuindo para a melhoria do desempenho. Vaswani *et al.* (2017) refinou ainda mais os mecanismos de atenção, introduzindo a arquitetura *transformer*. Essa arquitetura estabeleceu a base para os mecanismos de autoatenção, permitindo que os modelos ponderem dinamicamente a importância de diferentes elementos de entrada. A integração de mecanismos de atenção nas CNNs tornou-se uma técnica prevalente, aprimorando a capacidade da rede de capturar e explorar as dependências espaciais nos dados.

A capacidade do mecanismo de atenção permite que os modelos se concentrem seletivamente em regiões cruciais dos dados de entrada, como lesões nas plantas, contribuindo para uma extração de características aprimorada e previsões mais precisas. Como veremos, alguns artigos implementaram com sucesso essa tecnologia na avaliação da severidade de doenças nas plantas.

Natesan *et al.* (2022) introduziu uma Rede de Segmentação de Canal-Espaço (CSSN) com uma espinha dorsal pré-treinada VGG16 e um módulo de atenção espacial, demonstrando uma precisão geral de 99,76% e um F1-score de 0,997 para identificar e classificar doenças nas folhas. Um Módulo de Atenção Espacial é um componente arquitetural em redes neurais projetado para destacar regiões específicas da entrada com base na sua


importância espacial. Ele é comumente utilizado em tarefas de visão computacional para guiar o foco da rede nas áreas relevantes de uma imagem. Esse módulo calcula pesos ou coeficientes para diferentes regiões de entrada, enfatizando as áreas mais significativas, com esses pesos geralmente sendo aprendidos durante o treinamento da rede neural (Woo *et al.*, 2018).

Introduzindo uma arquitetura híbrida de meta-aprendizado de atenção multi-perspectiva (MPHAM) com um módulo de restrição de discriminabilidade e diversidade (DDCM) para classificação de doenças, Li *et al.* (2023) utilizou um conjunto de dados com 30 classes. Eles alcançaram previsões precisas para os níveis de severidade das doenças.

O estudo de Qu *et al.* (2024) empregou uma abordagem de aprendizado multitarefa profundo (MTL). Uma característica chave dessa abordagem foi a integração de um mecanismo de atenção coordenada, aprendizado residual e convolução em grupo, o que levou a resultados superiores em comparação com os modelos de última geração. O estudo foi realizado usando dados coletados pelos próprios autores.

Em outro estudo, Liu *et al.* (2022) propuseram um modelo CNN modificado com um mecanismo de atenção baseado na arquitetura SqueezeNext, alcançando uma precisão de 91,94% no conjunto de dados de teste, superando o modelo original SqueezeNext. O mecanismo de Atenção Coordenada (Coordinate Attention - CA) integrado ao SqueezeNext permite que a rede neural se concentre seletivamente em regiões específicas de interesse, como lesões nas folhas das plantas, ao mesmo tempo em que desconsidera informações menos relevantes. Ao melhorar as capacidades de extração de características sem aumentar significativamente o custo computacional, o mecanismo CA destaca as regiões essenciais da imagem, como as lesões nas folhas das plantas, para melhorar a precisão na classificação das doenças. Como ilustração, podemos ver a estrutura modificada e seu efeito nas Figuras 16a e 16b.

Figura 16 – Aplicação do mecanismo de atenção coordenada.



Fonte: (Liu *et al.*, 2022).

5.5.3 Transferência de Aprendizado, Lógica Fuzzy, Imagens Multiespectrais e Utilização de GAN

Outros estudos destacaram implementações alternativas. Dois estudos destacaram o uso da transferência de aprendizado. Wang *et al.* (2023) concentrou-se em técnicas de transferência de aprendizado para identificação de doenças nas folhas de soja, utilizando a arquitetura *Swin Transformer* (Liu, Z. *et al.*, 2021) com a espinha dorsal do EfficientNet. Yakkundimath *et al.* (2023) também empregaram transferência de aprendizado, utilizando ResNet-50, EfficientNet-B7 e CapsNet (Sabour *et al.*, 2017) para classificação de doenças.

Além disso, identificamos trabalhos que combinam CNN com abordagens de lógica fuzzy. Sibiyi e Sumbwanyambe (2021) exploraram várias arquiteturas de aprendizado profundo combinadas com lógica fuzzy, incluindo Google Net, U-Net, Rede Neural Convolutacional Profunda 3D (DCNN), ImageNet, Dense Net, CNN Profunda de 9 camadas, Rede Convolutacional Siamês Profunda e modelos CNN semelhantes à arquitetura padrão LeNet para previsão de severidade de doenças. Ji e Wu (2022) adotaram abordagem similar e utilizaram um modelo de segmentação semântica DeepLabV3+ baseado em ResNet50 para detecção de doenças, combinando CNN com elementos de lógica fuzzy.

Alguns estudos utilizam imagens multiespectrais e hiperespectrais. Xin Wang *et al.* (2023) exploraram a tecnologia de imagens hiperespectrais e a rede *Spectrum Transformer* para processar dados hiperespectrais na identificação da severidade de doenças. Além disso, Tianxiang Zhang *et al.* (2022) incorporaram imagens multiespectrais de UAV em uma arquitetura CNN para detectar a severidade da ferrugem amarela do trigo, demonstrando

a colaboração entre dados aéreos e redes neurais convolucionais no domínio agrícola.

Dois estudos aplicaram a abordagem de Rede Generativa Adversarial - Generative Adversarial Network (GAN) para aumento de dados. A Rede Generativa Adversarial (GAN) é uma arquitetura de rede neural introduzida por Ian Goodfellow *et al.* (2014). Ela consiste em duas redes, um gerador e um discriminador, treinadas simultaneamente por meio de um processo adversarial. O gerador cria dados sintéticos, enquanto o discriminador avalia a autenticidade desses dados em comparação com dados reais. Essa interação adversarial leva ao refinamento contínuo do gerador, gerando dados cada vez mais realistas.

Kumar e Kukreja (2023) utilizou uma CNN juntamente com o método STARGAN para classificar a doença da ferrugem amarela do trigo—o conjunto de dados, composto por 440 imagens, utilizou GAN para aumento de dados, gerando imagens de alta qualidade da classe minoritária.

De forma semelhante, Zeng *et al.* (2020) também utilizaram GAN para aumentar o tamanho do conjunto de dados de treinamento, denominado Deep Convolutional GANs (DCGANs). Eles usaram DCGANs para gerar novas amostras de imagens semelhantes às originais, auxiliando no treinamento do modelo de aprendizado profundo e melhorando o desempenho na detecção da severidade da doença.

5.5.4 Parâmetros de treinamento

A revisão enfatizou o papel crucial da seleção de hiperparâmetros de treinamento na otimização de modelos CNN para detecção de doenças em plantas e estimativa de severidade. Estudos indicam que taxas de aprendizado - *Learning Rates* (LRs) pequenas são mais eficazes na avaliação de doenças em plantas (Jepkoech *et al.*, 2021). Além disso, algoritmos adaptativos de LR com taxas apropriadas podem, às vezes, acelerar a convergência (Iiduka, 2020). Noon *et al.* (2022) e Weirong Chen *et al.* (2022) empregaram o Stochastic Gradient Descent (SGD), mas com diferentes taxas de aprendizado (0,01 e 0,001, respectivamente). Noon *et al.* (2022) obteve uma média de Precisão Média de 73,13%, enquanto Weirong Chen *et al.* (2022) alcançou uma precisão de validação de 94,39%, indicando que uma taxa de aprendizado mais baixa frequentemente resulta em uma precisão de validação melhor. De maneira semelhante, Wang *et al.* (2023) utilizou SGD com uma taxa de aprendizado de 0,001, alcançando uma precisão de classificação de 99,78% no conjunto de treinamento, destacando a eficácia do ajuste fino das LRs.

A escolha do tamanho do lote e o número de épocas influencia diretamente a convergência e a generalização dos modelos. Um tamanho de lote de 32 é uma escolha comum entre os autores, como observado em Noon *et al.* (2022), Zeng *et al.* (2020) e Esgario *et al.* (2020). Em contraste, Liu *et al.* (2022) e Wang *et al.* (2023) exploraram tamanhos de lote menores, de 16 e 4, para ajustar o desempenho do modelo. O número de épocas variou significativamente, com Liu *et al.* (2022) e Chelloug *et al.* (2023) alcançando resultados ótimos com 100 épocas. Em comparação, Zeng *et al.* (2020) encontrou que 60 épocas

foram suficientes para o Inception_v3, melhorando a precisão de 74,38% para 92,60% após o aumento de dados.

A revisão dos hiperparâmetros nesses estudos ilustra que, embora não exista uma abordagem única que funcione para todos os casos, certos padrões surgem como boas práticas. Estes incluem o uso eficaz de taxa de aprendizado, otimizadores como SGD e Adam, e a incorporação de técnicas de aumento de dados e regularização. Dado o grande número de variáveis envolvidas, o ajuste ideal é frequentemente alcançado por meio de tentativa e erro durante o processo de ajuste fino. Alinhar esses hiperparâmetros com a arquitetura específica e as características do conjunto de dados é crucial para alcançar um desempenho superior do modelo nas tarefas de detecção de doenças em plantas e estimativa de severidade.

5.5.5 Pesquisa recente

Esta revisão indica que, em 2023 e 2024, as pesquisas adotaram abordagens diversas e inovadoras, com um foco constante no aprimoramento e avanço dos modelos. Notavelmente, estruturas melhoradas/híbridas são predominantes, compondo 50% dos trabalhos totais, destacando uma tendência em melhorar as estruturas clássicas. A utilização contínua de tecnologias emergentes, como memória de longo e curto prazo, mecanismo de atenção, transformer Swin e GAN, reflete um compromisso no desenvolvimento de soluções mais robustas e eficientes. A adoção de técnicas de transferência de aprendizado e a exploração de modelos mais leves indicam uma dedicação à eficiência computacional e à aplicabilidade no mundo real.

5.6 RQ4: Quais foram os desafios no desenvolvimento da pesquisa?

Os resultados da nossa revisão destacam desafios complexos na pesquisa sobre doenças em plantas usando CNNs, incluindo plantas acometidas por mais de uma doença, limitações em conjuntos de dados e a necessidade de uma generalização eficaz do modelo. Para melhor compreensão, categorizamos os desafios e limitações da seguinte forma:

5.6.1 Desafios relacionados à doença

- *Presença de múltiplas doenças em diferentes estágios:* A detecção de doenças em plantas torna-se complicada quando um único hospedeiro enfrenta múltiplos estresses e quando diferentes estágios da doença se manifestam em uma única folha. Essa complexidade desafia a precisão da detecção e da classificação (Noon *et al.*, 2022; Zhang, T. *et al.*, 2022). Além disso, a presença de doenças com sintomas análogos complica sua diferenciação, especialmente em imagens onde múltiplas folhas se sobrepõem, aumentando o desafio da classificação precisa (Noon *et al.*, 2022; Xu *et al.*, 2024).

5.6.2 Desafios relacionados ao conjunto de dados

- *Limitações do conjunto de dados:* Desafios surgem devido às limitações inerentes aos conjuntos de dados coletados de fontes específicas, indicando a necessidade de datasets mais amplos e representativos (Zeng *et al.*, 2020; Esgario *et al.*, 2020). A escassez de conjuntos de dados em grande escala para doenças específicas e a necessidade de confirmação por especialistas e técnicas eficazes de aumento de dados adicionam complexidade ao processo de treinamento (Yakkundimath *et al.*, 2023). Além disso, os desafios no avanço da pesquisa sobre doenças em plantas são agravados pela necessidade de condições controladas durante a captura de imagens, pelo tamanho e diversidade limitados dos conjuntos de dados anotados e pelo impacto potencial de outros tipos de danos às folhas (Lin *et al.*, 2019). Hayit, Endes e Hayit (2024) também destaca a necessidade de rotulagem precisa para a avaliação da severidade da doença.
- *Desequilíbrio na distribuição de amostras:* A distribuição desigual de amostras dentro dos conjuntos de dados de doenças de plantas representa um desafio no desenvolvimento de modelos, afetando a precisão das previsões (Xiang *et al.*, 2021). Surgem desafios na coleta de imagens diversificadas de doenças e na criação de conjuntos de dados equilibrados, com igual representação de todos os estágios de severidade, influenciando o treinamento e o desempenho do modelo (Haque *et al.*, 2022).
- *Processos de aquisição e rotulagem de imagens:* Dificuldades na aquisição de imagens de alta qualidade, nos processos trabalhosos de rotulagem e na seleção de hiperparâmetros apropriados para o modelo representam desafios adicionais na detecção de doenças (Hayit, 2021).


5.6.3 Desafios no desempenho do modelo

- *Garantir a generalização do modelo:* Garantir que um modelo possa generalizar em diversas condições e convergir durante o treinamento é um desafio crítico no desenvolvimento de modelos robustos e aplicáveis (Noon *et al.*, 2022).
- *Complexidades ambientais:* A natureza intrincada do ambiente afeta significativamente o desempenho do modelo, e há riscos de overfitting devido ao tamanho limitado dos conjuntos de dados em ambientes agrícolas (Agarwal *et al.*, 2021; Liu *et al.*, 2022; Wang, X. *et al.*, 2023).
- *Implantação móvel:* Alcançar eficiência de memória e precisão razoável de classificação para modelos baseados em CNN implantados offline em dispositivos móveis representa desafios para aplicações práticas (Chen, W. *et al.*, 2022).

- *Avaliação em tempo real*: Surgem desafios na avaliação em tempo real em campo, exigindo segmentação precisa das regiões de doença em meio a planos de fundos complexos (Liu, B.-Y. *et al.*, 2022). As metodologias existentes enfrentam limitações na detecção e classificação precisas, destacando a necessidade de avanços para lidar com as complexidades do mundo real (Thenappan *et al.*, 2023; Rajpal *et al.*, 2022).

A Figura 17 resume os métodos e as dificuldades destacadas nas pesquisas.

Figura 17 – Resumo dos Métodos e Desafios.



5.7 RQ5: Quais são as sugestões para trabalhos futuros?

As direções futuras para a pesquisa em detecção de doenças em plantas e classificação de severidade abrangem uma variedade de aspectos cruciais, conforme sugerido por diferentes autores. Naturalmente, uma parte significativa das sugestões para trabalhos futuros reflete os desafios abordados na RQ4.

Noon *et al.* (2022) e Fernández-Campos *et al.* (2021) enfatizam a expansão dos conjuntos de dados, incluindo várias culturas e doenças, para melhorar a robustez e a aplicabilidade dos modelos em diversas condições. Tianxiang Zhang *et al.* (2022) propõe explorar métodos de aprendizado com poucos exemplos e aprendizado profundo auto-supervisionado com dados rotulados limitados para detecção precoce da ferrugem amarela.

Agarwal *et al.* (2021) recomenda o uso de técnicas de transferência de aprendizado para melhorar a precisão do modelo e técnicas avançadas de segmentação para estimar com precisão a severidade das doenças nas folhas de pepino.

Xin Wang *et al.* (2023) também propõe expandir os conjuntos de dados, explorar técnicas de aumento de dados, lidar com a complexidade dos ambientes de campo e enfrentar os desafios associados a conjuntos de dados pequenos. Pal e Kumar (2023)

defendem a detecção de doenças em diferentes fases e locais, estendendo o método proposto para um aplicativo móvel e considerando técnicas de otimização computacional.

Ji e Wu (2022) sugerem mais pesquisas em diversas condições de imagem, otimizando a arquitetura de aprendizado profundo para severidade de doenças em plantas e integrando segmentação semântica orientada por aprendizado profundo para tarefas de doenças. O autor também sugere a expansão de conjuntos de dados, a exploração de arquiteturas adicionais de CNN e a integração de imagens multi-espectrais ou hiperespectrais.

Autores como Rajasree e Latha (2023) enfatizam a detecção de severidade de doenças além das folhas, o aprimoramento contínuo dos conjuntos de dados e a priorização de modelos leves. Kumar e Kukreja (2023) propõe sistemas inteligentes de alerta para agricultores, adaptando modelos para diversas doenças de plantas e reconhecendo desafios. Gao *et al.* (2021) destaca a importância de melhorar a precisão da segmentação de lesões e explorar sensores hiperespectrais para detecção de doenças. Finalmente, Chunshan Wang *et al.* (2021) recomenda refinar a classificação de severidade de doenças, explorar outras arquiteturas de CNN e expandir os conjuntos de dados para incluir diversas condições de iluminação.

Nossas descobertas mostram que as direções futuras para a pesquisa em detecção de doenças em plantas e classificação de severidade enfatizam a expansão dos conjuntos de dados, o aprimoramento da robustez dos modelos e a exploração de técnicas avançadas, como aprendizado profundo por transferência e auto-supervisionado. As recomendações incluem otimização das arquiteturas de aprendizado profundo, enfrentamento dos desafios associados a conjuntos de dados pequenos e integração de imagens multi-espectrais ou hiperespectrais.

A Tabela 5 resume as principais informações extraídas dos 64 artigos analisados.

Tabela 5 – Estudos abordados na revisão e suas principais características.

Autoria	Doença/Cultura	Conjunto de Dados	Método	Métricas
(Noon <i>et al.</i> , 2022)	Múltiplas Doenças de Folhas de Algodão	Auto-coletado - 1200 Imagens	Modified Spatial Pyramid Pooling (SPP) no Modelo YOLOX	Acurácia Média: 69.90%
(Zhang, T. <i>et al.</i> , 2022)	Ferrugem Amarela do Trigo	Auto-coletado - Imagens Multiespectrais de UAV	Rede Neural Convolutacional (CNN) para Classificação e Segmentação de Lesões	Acurácia Média: 83.68%, Acurácia Máxima: 91.77%
(Chelloug <i>et al.</i> , 2023)	Manchas Bacterianas, Fúngicas e Virais no Arroz	Conjunto de Dados PlantVillage	CNN para Identificação de Doenças, Framework de Aprendizado por Reforço Profundo (DRL) com Assistência do EfficientNet	Acurácia: 63.8%
(Zeng <i>et al.</i> , 2020)	Huanglongbing (HLB) em Laranjeira	PlantVillage, CrowdAI	CNN para Classificação de Folhas Infectadas por HLB, Augmentação de Dados com DCGANs	Acurácia: 94.5% (com DCGANs), 91.5% (sem DCGANs)
(Xiang <i>et al.</i> , 2021)	-	-	Modelo de Rede Neural Leve (L-CSMS) com Validação Cruzada em Cinco Dobramentos	-
(Agarwal <i>et al.</i> , 2021)	Planta de Pepino	Auto-coletado - 952 Imagens	LeNet-5 Modificado para Classificação de Doenças, Segmentação de Lesões	Acurácia: 93.75%
(Liu <i>et al.</i> , 2022)	Folha de Maçã - Diversas	-	CNN Modificada com Mecanismo de Atenção, Kernel de Convolução Multi-escala e Mecanismo de Atenção Coordenada	Acurácia: 91.94%
(Wang <i>et al.</i> , 2023)	Mancha Bacteriana da Soja	Auto-coletado - 260 Imagens	Swin Transformer com Backbone EfficientNet, Transfer Learning	Acurácia: 99,64%
(Pal; Kumar, 2023)	Mancha Bacteriana da Soja	PlantDoc, PlantVillage	Arquiteturas de CNN (INC-VGGN, Kohonen-Based) para Detecção e Classificação de Doenças	-
(Li <i>et al.</i> , 2023)	Diversas	Conjunto de Dados Montado com 10 Espécies de Plantas e 61 Doenças	Arquitetura de Meta-Aprendizado Híbrida de Atenção Multiperspectiva (MPHAM) com Módulo de Restrição de Discriminabilidade e Diversidade (DDCM)	-
(Verma; Chug; Singh; Singh, 2023a)	Requeima Precoce do Tomate	Auto-coletado (Quantidade Não Especificada)	Quatro Técnicas de Realce de Imagem, Seis Arquiteturas de CNN (AlexNet, ResNet18, ResNet50, ResNet101, SqueezeNet, Inception V3)	Acurácia para Detecção de Doenças: 96,43% a 99,55%, Avaliação de Severidade: 66,88% a 78,98%
(Liang <i>et al.</i> , 2019)	Diversas	Não Especificado	PD2SE-Net (Sistema de Diagnóstico Assistido por Computador Multifuncional) Combinando Estruturas Residuais e Unidades Shuffle	Acurácias Gerais: 91% (Estimativa de Severidade de Doença), 99% (Reconhecimento de Espécies de Plantas), 98% (Classificação de Doenças em Plantas)

Tabela 5 – Tabela de trabalhos analisados (continuação)

Autoria	Doença/Cultura	Conjunto de Dados	Método	Métricas
(Chen, W. <i>et al.</i> , 2022)	Diversas Doenças da Batata	PlantVillage - 3246 Imagens	Rede Leve MobOca_Net Baseada no MobileNet-V2, Módulos de Atenção Espacial e de Canal, Bloco de Convolução Octave	Acurácia: 97,73%
(Hamila <i>et al.</i> , 2024)	Fusariose em Trigo (FHB)	94 Amostras Escaneadas	Estimativa de Severidade usando CNNs 3D. As arquiteturas incluíram vários modelos de redes neurais convolucionais 3D desenvolvidos por meio de uma busca em grade monitorada para detectar sintomas de FHB	Coefficiente de Determinação (R^2): 94,74 entre os níveis de severidade previstos e os de referência
(Yakkundimath <i>et al.</i> , 2023)	Brusone do Arroz	Auto-coletado - 3987 Imagens	Várias Técnicas de Aumento de Imagem, ResNet-50, EfficientNet-B7, CapsNet	Acurácias - ResNet-50: 85,10%, EfficientNet-B7: 88,72%, CapsNet: 90,79%
(Yang; Li <i>et al.</i> , 2024)	Tomate - Requeima Tardia	Conjunto de Dados AI Challenger 2018 - 31.718 Imagens	Estrutura de multi-rótulos chamada LDI-NET composta por um módulo tokenizador de características, um módulo codificador de tokens e um módulo decodificador de multi-rótulos	Acurácia de 99,42%, 88,55% e 87,40% para acurácia da planta, acurácia da severidade e acurácia planta-doença-severidade, respectivamente.
(Qu <i>et al.</i> , 2024)	Mirtilo - Doença Múmia de Fruto	Auto-coletado - 927 Imagens	Aprendizado multitarefa (MTL) Peep integrando aprendizado residual, mecanismo de atenção coordenada e convolução em grupo	Relatada maior acurácia de detecção em comparação com modelos de última geração
(Shruthi; Nagaveni, 2023)	Tomate - Diversas Doenças	Plant Village - 15.961 Imagens	Modelo Híbrido de CNN TomSevNet com Resíduos Autorregulados, Bloco Inception, Otimizador Adadelta	Acurácia nos Testes: 96,91%, F1-Score: 97%
(Goshika <i>et al.</i> , 2023)	Soja - Diversas Doenças	Auto-coletado - 2.930 Imagens	Arquitetura YOLOv5s para detecção de objetos e classificação dos níveis de dano em folhas de soja	Não especificado
(Esgario <i>et al.</i> , 2020)	Cafeeiro Arábica	Não Especificado	Abordagem de Aprendizado Multitarefa	Acurácia: 97,07% com ResNet50
(Lamba, S. <i>et al.</i> , 2023)	Mancha Bacteriana	Auto-coletado - 1.856 Imagens	Integração de Rede Neural Convolucional (CNN) e Long Short-Term Memory (LSTM)	Acurácia: 92%, 88%, 86% e 94% para 4 classes de severidade. Acurácia Geral: 92%.
(Verma; Chug; Singh; Singh, 2023b)	Tomate - Requeima Tardia e Requeima Precoce	PlantVillage	Estrutura Híbrida Usando MobileNetV2 com Função de Ativação SiLU6 e Redes Capsulares	Acurácia Não Especificada
(Wang, Y. <i>et al.</i> , 2024)	Míldio em Pepino	Dados Ambientais de Estufa	Combinação de CNN e LSTM com fatores ambientais de estufa	MAE, MSE, RMSE e coeficiente de determinação (R^2) de 0,069, 0,0098, 0,0991 e 0,9127, respectivamente. Erro Máximo: 16,94%.

Tabela 5 – Tabela de trabalhos analisados (continuação)

Autoria	Doença/Cultura	Conjunto de Dados	Método	Métricas
(Ji; Wu, 2022)	Videira - Doença Mancha Preta das Uvas	Auto-coletado	Modelo de Segmentação Semântica DeepLabV3+ Baseado em ResNet50	Acurácia Geral: 97,75%
(Fernández-Campos <i>et al.</i> , 2021)	Brusone em Espigas de Trigo	Auto-coletado - 1.800 Imagens	CNNs (VGG-16, ResNet-50, InceptionV3) para Classificação de Imagens	Acurácia: 94,44%, F1-Score: 94%
(Sibiya; Sumbwanyambe, 2021)	Milho - Ferrugem Comum	Auto-coletado - 155 Imagens	Várias Arquiteturas de Deep Learning para Predição de Severidade da Doença (Google Net, U-Net, 3D DCNN, ImageNet, Dense Net, CNN Profunda de 9 Camadas, Deep Siamese, CNN Le Net)	Acurácia nos Testes: 89%
(Natesan <i>et al.</i> , 2022)	Diversas	Conjunto de Dados PlantVillage, Imagens de Fazendas e Jardins	Rede de Segmentação Canal-Espaço (CSSN) com Backbone VGG16 Pré-Treinado e Módulo de Atenção Espacial	Acurácia Geral: 99,76%, F1-Score: 99,7%
(Ramcharan <i>et al.</i> , 2019)	Mandioca - Doença do Mosaico (CMD), Doença da Mancha Marrom (CBSD), Danos por Ácaro Verde (CGM)	Auto-coletado - 2.415 Imagens	Modelo Single Shot Multibox (SSD) com Detector MobileNet e Classificador Pré-Treinado no Conjunto de Dados COCO	Acurácia Máxima: 81,7%
(Hayit; Endes; Hayit, 2024)	Grão-de-Bico - Fusariose	Auto-coletado - Quantidade Não Especificada	Metodologia utilizando modelos de deep learning pré-treinados para classificação (AlexNet, GoogLeNet, VGG e outros)	Melhor Acurácia: 90% para DenseNet-201
(Abdalla <i>et al.</i> , 2024)	Algodão - Doença Fusarium oxysporum	Imagens UAV Auto-coletadas	Combinação de Redes Neurais Convolucionais (CNNs) e Redes Bidirecionais Long Short-Term Memory (BiLSTM)	Maior Acurácia Geral: 89,7% para o modelo ResNet101-BiLSTM
(Upadhyay; Kumar, 2021)	Arroz - Mancha Parda	Auto-coletado - 4.000 Amostras por Classe (Folhas Saudáveis, Mancha Parda, Carvão das Folhas, Requeima Bacteriana)	Técnicas de Processamento de Imagem e Deep Learning (GoogleNet, AlexNet, CNN)	Acurácia: 83,57% (Sem Segmentação), 99,7% (Com Segmentação)
(Rajpal <i>et al.</i> , 2022)	Diversas Plantas e Doenças	PlantVillage - 8.000 Imagens	Análise Multi-Resolução usando Transformada de Wavelet Discreta (DWT) e Análise de Componentes Principais (PCA) combinadas com Redes Neurais Profundas (DNNs)	Acurácia: 99% para identificação de doenças e 90% para estimativa de severidade da doença.

Tabela 5 – Tabela de trabalhos analisados (continuação)

Autoria	Doença/Cultura	Conjunto de Dados	Método	Métricas
(Xu <i>et al.</i> , 2024)	Batata - Requeima Precoce / Requeima Tardia	PlantVillage e Kaggle	Abordagem em duas etapas para classificação da severidade da doença, combinando ConvNeXt V2 e bloco Segformer	MIoU: 88,5%; Acurácia na Classificação: 97,86%
(Verma; Chug; Singh; Singh; Singh, 2022)	Requeima Tardia - Tomate	Conjunto de Dados PlantVillage	Abordagem Aprimorada de Computação de Características com Base em Redes Squeeze and Excitation (SE), Combinadas com Redes Capsulares (CapsNet)	Acurácia SE-Res-CapsNet: 93,75%
(Patil <i>et al.</i> , 2022)	Arroz - Mancha Parda, Requeima, Requeima Bacteriana	Auto-coletado - 1.200 Imagens	Metodologias Avançadas de Deep Learning (FRCNN, EfficientNet-B0)	Acurácia: 96,43%
(Fenu <i>et al.</i> , 2021)	Pera - Diversas	Auto-coletado - 3.057 Imagens	Sistema Multioutput Baseado em CNNs (VGG-16, VGG-19, ResNet50, InceptionV3, MobileNetV2, EfficientNet-B0)	Acurácia Máxima para Estresse Biótico: 90,68% (InceptionV3), Acurácia Máxima para Severidade: 78,31%
(Rajasree; Latha, 2023)	Tomate - Diversas	Auto-coletado - 2.000 Imagens	Modelo Aprimorado YOLO-X para Detecção de Doenças e Classificação de Severidade	Pontuações mAP de 73,42% (Treinamento), 72,31% (Teste)
(Clohessy <i>et al.</i> , 2021)	Amendoim - Vírus do Murchamento do Tomateiro (TSWV)	Auto-coletado - 227 Exemplos de Nanismo e Manchamento, 379 Instâncias de Clorose	CNNs para Análise de Imagens (Faster R-CNN, YOLOv3)	Nenhuma Acurácia Especificada
(Wang, X. <i>et al.</i> , 2023)	Tomate - Murcha Bacteriana (BW)	293 Imagens Hiperespectrais	Rede Spectrum Transformer com Tecnologia de Imagem Hiperespectral	Acurácia Geral: 91,93%
(Chowdhury <i>et al.</i> , 2024)	Batata - Requeima Precoce/Tardia	Kaggle - 5.720 Imagens	Combinação das Arquiteturas DenseNet201 e ResNet50V2	Acurácia Geral: 99,23%
(Kumar; Kukreja, 2023)	Trigo - Ferrugem Amarela	Auto-coletado	Abordagem Combinada Usando STARGAN e CNN	Acurácia: 95,6%
(Sreedevi; Manike, 2024)	Tomate - Diversas Doenças	Auto-coletado	Modelo ResNet Baseado em Convolução Dilatada Multiescala Adaptativa, Integrando as Otimizações Elephant Herding (EHO) e Spider Monkey (SMO)	Acurácia: 85%
(Bhujel <i>et al.</i> , 2022)	Morango - Mofo Cinzento	Auto-coletado - 1.200 Imagens	Modelo U-Net Modificado, Modelo XGBoost para Segmentação Semântica	Acurácia por Pixel: 96,4%, Dice: 85,3%, IoU: 75,3%
(Thenappan <i>et al.</i> , 2023)	Trigo - Diversas Doenças	Banco de Dados Online	CNN Baseada em Hiperparâmetros Tanh (HT-CNN) para Classificação de Doenças, Hex-D-VCC para Extração de Bordas e Análise de Severidade	Especificidade: 98,79%, Acurácia: 98,25%, Precisão: 97,64%

Tabela 5 – Tabela de trabalhos analisados (continuação)

Autoria	Doença/Cultura	Conjunto de Dados	Método	Métricas
(Rajpal <i>et al.</i> , 2022)	Arroz - Diversas Doenças	PlantVillage - 8.000 Imagens	Análise Multiresolução Usando DWT com Wavelets Ortogonais, Arquiteturas DNN (AlexNet, ResNet101, InceptionV3)	-
(Gao <i>et al.</i> , 2021)	Batata - Requeima Tardia	Auto-coletado	Deep Learning, CNNs para Reconhecimento de Lesões e Quantificação de Severidade, Abordagem de Predição Multi-Escala	Acurácia Geral: 91%, IoU: 63%
(Wang, C. <i>et al.</i> , 2021)	Pepino - Míldio, Oídio, Doença do Vírus do Pepino	Auto-coletado - 1.000 Imagens	Estrutura de Segmentação em Dois Estágios (DeepLabV3+, U-Net), Classificação da Severidade com Base na Área de Lesões	Acurácia Geral: 96,5%, Precisão: 96,5%, Revocação: 96,5%, F1-Score: 96,5%
(Yang; Wang <i>et al.</i> , 2023)	Diversas	Bancos de Dados Públicos - 5.748 Amostras	Triple-Branch Swin Transformer e Modelo com Supervisão Profunda para Identificação de Doenças e Severidade	Acurácia Geral: 94,67%, F1-Score: 93,90%
(Chen, L.-C. <i>et al.</i> , 2017)	Arroz - Estria Bacteriana (BLS)	Auto-coletado	CNNs para Classificação de Doenças e Estimativa de Severidade (MobileNet, Self-Structured ANN, AlexNet, OverFeat, Xception, DenseNet, SE MobileNet)	Acurácia na Estimativa de Severidade: 94%
(Goncalves <i>et al.</i> , 2021)	Folhas de Café Afetadas por CLM (Inseto)	Auto-coletado - 612 Imagens de Treinamento, 154 Imagens de Teste	Seis Arquiteturas CNN para Segmentação Semântica (U-Net, SegNet, PSPNet, FPN, DeepLabv3+)	Estimativas Precisam de Severidade Percentual: 96%
(Hu <i>et al.</i> , 2021)	Chá - Murcha das Folhas de Chá (TLB)	Auto-coletado	Métodos Baseados em Deep Learning, Modelo Faster R-CNN com Estrutura PRPN, VGG16 para Análise de Severidade	Precisão: 84,9%
(Ji; Zhang <i>et al.</i> , 2020)	Milho e Uva - Puccinia Polysora, Mancha Foliar de Curvularia, Fungos de Podridão Negra	12.691 - Plataforma AI Challenger	BR-CNNs Baseados no Algoritmo BR Multi-Label Learning, Abordagens Deep CNN (VGGNet, GoogLeNet, ResNet, DenseNet, SE-Net, MobileNet-V2)	Melhor Acurácia de Teste: 86,70%
(Ilyas <i>et al.</i> , 2022)	Páprica - Diversas Doenças	3.000 Imagens, 500 para Cada Doença	Sistema Baseado em Deep Learning Combinando Duas CNNs em Uma Estrutura (DDL, DSA, IU)	Acurácia Geral: 92,21%
(Liu, B.-Y. <i>et al.</i> , 2022)	Macieira - Mancha Foliar de Alternaria	Auto-coletado - 5.382 Imagens de Folhas Saudáveis e Casos de Doenças	Algoritmos de Segmentação de Imagem Baseados em Deep Learning (DeepLabV3+, PSPNet, U-Net)	Precisão: 95,84%, Revocação: 95,54%, MIoU: 92,05%

Tabela 5 – Tabela de trabalhos analisados (continuação)

Autoria	Doença/Cultura	Conjunto de Dados	Método	Métricas
(Adem; Ozguven; Altas, 2023)	Beterraba Açucareira - Mancha Foliar	Auto-coletado - 1.000 Imagens, 250 em Cada Categoria de Severidade	Abordagem Híbrida Usando Processamento de Imagens e Modelos de Deep Learning (Faster R-CNN, SSD, VGG16, YOLOv4)	Acurácia Geral: 96,47%, Sensibilidade: 96,00%, Especificidade: 98,00%
(Mathieu <i>et al.</i> , 2024)	Trigo - Mancha de Septoria (STB)	Auto-coletado	Arquitetura U-Net para quantificação de necrose	Precisão: 95% para necrose
(Lamba K., V. <i>et al.</i> , 2023)	Arroz - Brusone	Auto-coletado - 1.908 Imagens	Rede Neural Convolucional (CNN) para Extração de Características, Máquina de Vetores de Suporte (SVM) para Identificação de Nível de Severidade	Acurácia: 97%
(Liu, Weizhen <i>et al.</i> , 2024)	Trigo - Ferrugem Estrimada	Auto-coletado - 724 Imagens	Modelo de Segmentação Leve em Dois Estágios	MIoU: 83,44%
(Sreedevi; Manike, 2024)	Tomate - Diversas doenças	Kaggle	SD-GHHO (Algoritmo de Otimização de Gafanhoto Auto-Dual) e MRNN para classificação de doenças	Acurácia do SD-GHHO-MRNN foi 66,8%, 58,8%, 60,7% e 58,5% mais avançada do que CNN, TL-DCNN, AlexNet-VGG16 e RNN, respectivamente
(Lin <i>et al.</i> , 2019)	Pepino - Oídio	Auto-coletado - 50 Imagens	Deep Learning e Tecnologia CNN, Arquitetura U-Net	Acurácia Geral: 94,5%
(Haque <i>et al.</i> , 2022)	Milho - Mancha Foliar de Maydis	Auto-coletado - 1.760 Imagens	Estrutura CNN Leve com Dois Módulos Inception Modificados	Acurácia de Classificação: 99,13%, F1-Score: 98,97%
(Su <i>et al.</i> , 2020)	Trigo - Giberela	Auto-coletado - 1.650 Imagens	Algoritmo de Detecção de Doenças Baseado em Deep Learning, Modelos Dual Mask-RCNN	Precisão Média: 89%, Revocação Média: 87%
(Prabhakar; Purushothaman; Awasthi, 2020)	Tomate - Pinta Preta	PlantVillage	Foldscope para Identificação de Doenças, Arquiteturas Pré-Treinadas (VGG16, VGG19, GoogLeNet, AlexNet, ResNet50, ResNet101) para Avaliação de Severidade	Acurácia do ResNet101: 94,6%
(Hayit, 2021)	Trigo - Ferrugem Amarela	Auto-coletado - 3.750 Imagens	Modelo de Rede Neural Convolucional (ConvNet) Yellow-Rust-Xception, Transfer Learning com Xception, MobileNet, ResNet	Acurácia do Modelo Yellow-Rust-Xception: 91,17%

6 Conclusão

Nos últimos anos, a aplicação de Redes Neurais Convolucionais na análise de doenças em plantas tem avançado significativamente. A evolução dessas redes, de uma simples detecção de doenças para uma análise detalhada de severidade, representa um grande progresso. Esta revisão destaca os avanços atuais e os desafios persistentes, estabelecendo uma base para futuras pesquisas que impulsionarão inovações capazes de melhorar significativamente o diagnóstico precoce, o monitoramento contínuo e o manejo geral das doenças em plantas.

Esta revisão mostrou alguns avanços nesse campo. Foi possível demonstrar o status atual, as dificuldades e as perspectivas futuras. Assim, este trabalho fornece uma referência para novas pesquisas explorarem e ampliarem o conhecimento sobre este tema, oferecendo informações e abordagens que podem ser aprimoradas e expandidas. Os desafios mencionados oferecem um vasto campo de investigação e possibilidades para inovação. Novas pesquisas podem contribuir para o desenvolvimento de soluções práticas e eficazes que auxiliem no diagnóstico precoce, no monitoramento contínuo e no manejo eficiente das doenças em plantas.

Referências

- ABDALLA, Alwaseela *et al.* Assessing fusarium oxysporum disease severity in cotton using unmanned aerial system images and a hybrid domain adaptation deep learning time series model. **Biosystems Engineering**, Elsevier, v. 237, p. 220–231, 2024.
- ADEM, Kemal; OZGUVEN, Mehmet Metin; ALTAS, Ziya. A sugar beet leaf disease classification method based on image processing and deep learning. **Multimedia Tools and Applications**, Springer, v. 82, n. 8, p. 12577–12594, 2023.
- AGARWAL *et al.* A new Conv2D model with modified ReLU activation function for identification of disease type and severity in cucumber plant. **Sustainable Computing: Informatics and Systems**, Elsevier, v. 30, p. 100473, 2021.
- AHMAD *et al.* A survey on using deep learning techniques for plant disease diagnosis and recommendations for development of appropriate tools. **Smart Agricultural Technology**, Elsevier, v. 3, p. 100083, 2023.
- ALBAWI, Saad *et al.* Understanding of a convolutional neural network. **2017 International Conference on Engineering and Technology (ICET)**, p. 1–6, 2017. Disponível em: <https://api.semanticscholar.org/CorpusID:3819513>.
- AMORIM, Lilian *et al.* Manual de fitopatologia, 2016.

BADRINARAYANAN *et al.* Segnet: A deep convolutional encoder-decoder architecture for image segmentation. **IEEE transactions on pattern analysis and machine intelligence**, IEEE, v. 39, n. 12, p. 2481–2495, 2017.

BAHDANAU *et al.* Neural machine translation by jointly learning to align and translate. **arXiv preprint arXiv:1409.0473**, 2014.

BARBEDO, J.G.A. Digital image processing techniques for detecting, quantifying and classifying plant diseases. **SpringerPlus**, SpringerOpen, v. 2, n. 1, p. 1–12, 2013.

BARBURICEANU, Stefania *et al.* Convolutional neural networks for texture feature extraction. Applications to leaf disease classification in precision agriculture. **IEEE Access**, IEEE, v. 9, p. 160085–160103, 2021.

BHARGAV, Ganipisetty Akhil; PATHAK, Dr.Ajita. Plant Disease Detection and it's Health Monitoring using CNN and Arduino. **International Journal for Research in Applied Science and Engineering Technology**, 2023. Disponível em: <https://api.semanticscholar.org/CorpusID:259039513>.

BHUJEL, Anil *et al.* Detection of gray mold disease and its severity on strawberry using deep learning networks. **Journal of Plant Diseases and Protection**, Springer, v. 129, n. 3, p. 579–592, 2022.

BISONG, Ekaba. Convolutional Neural Networks (CNN). **Building Machine Learning and Deep Learning Models on Google Cloud Platform**, 2019. Disponível em: <https://api.semanticscholar.org/CorpusID:204094429>.

BOCK, and others. Detection and measurement of plant disease symptoms using visible-wavelength photography and image analysis. **CABI Reviews**, CABI Wallingford UK, n. 2011, p. 1–15, 2011.

BOCK, C.H. *et al.* From visual estimates to fully automated sensor-based measurements of plant disease severity: status and challenges for improving accuracy. **Phytopathology Research**, BioMed Central, v. 2, n. 1, p. 1–30, 2020.

BONDRE *et al.* Recent advances in agricultural disease image recognition technologies: A review. **Concurrency and Computation: Practice and Experience**, Wiley Online Library, v. 35, n. 9, e7644, 2023.

BROOKS, Justin. **COCO Annotator**. [*S. l.: s. n.*], 2019. <https://github.com/jsbroks/coco-annotator/>.

CAMPBELL *et al.* **Introduction to plant disease epidemiology**. [*S. l.*]: John Wiley & Sons., 1990.

CARMONA, Marcelo Aníbal *et al.* Rapid emergency response to yellow rust epidemics caused by newly introduced lineages of *Puccinia striiformis* f. sp. *tritici* in Argentina. **Tropical Plant Pathology**, p. 1–7, 2019. Disponível em: <https://api.semanticscholar.org/CorpusID:189763295>.

CHELLOUG, Samia Allaoua *et al.* MULTINET: A Multi-Agent DRL and EfficientNet Assisted Framework for 3D Plant Leaf Disease Identification and Severity Quantification. **IEEE Access**, IEEE, 2023.

CHEN, Liang-Chieh *et al.* Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs. **IEEE transactions on pattern analysis and machine intelligence**, IEEE, v. 40, n. 4, p. 834–848, 2017.

CHEN, Shuo *et al.* An approach for rice bacterial leaf streak disease segmentation and disease severity estimation. **Agriculture**, MDPI, v. 11, n. 5, p. 420, 2021.

CHEN, Weirong *et al.* Mobile convolution neural network for the recognition of potato leaf disease images. **Multimedia Tools and Applications**, Springer, v. 81, n. 15, p. 20797–20816, 2022.

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

CHOTHANI, Ekta P. *et al.* Impact of Weather Parameter on Early Blight Epidemiology in Tomato Crop. **International Journal of Current Microbiology and Applied Sciences**, v. 6, p. 3160–3166, 2017. Disponível em: <https://api.semanticscholar.org/CorpusID:133665579>.

CHOWDHURY, Nishu *et al.* Potato leaf disease detection through ensemble average deep learning model and classifying the disease severity. **Indonesian Journal of Electrical Engineering and Computer Science**, v. 35, n. 1, p. 494–502, 2024.

CLOHESSY, James W *et al.* Development of a high-throughput plant disease symptom severity assessment tool using machine learning image analysis and integrated geolocation. **Computers and Electronics in Agriculture**, Elsevier, v. 184, p. 106089, 2021.

DOMINGOS, Pedro. A few useful things to know about machine learning. **Communications of the ACM**, ACM New York, NY, USA, v. 55, n. 10, p. 78–87, 2012.

DUTTA, Abhishek; ZISSERMAN, Andrew. The VIA Annotation Software for Images, Audio and Video. *In: PROCEEDINGS of the 27th ACM International Conference on Multimedia*. Nice, France: ACM, 2019. (MM '19). ISBN 978-1-4503-6889-6/19/10. DOI: 10.1145/3343031.3350535. Disponível em: <https://doi.org/10.1145/3343031.3350535>.

ELMAN, Jeffrey L. Finding structure in time. **Cognitive science**, Wiley Online Library, v. 14, n. 2, p. 179–211, 1990.

ESGARIO *et al.* Deep learning for classification and severity estimation of coffee leaf biotic stress. **Computers and Electronics in Agriculture**, v. 169, p. 105162, 2020.

FAYE, Demba *et al.* Plant Disease Severity Assessment Based on Machine Learning and Deep Learning: A Survey. **Journal of Computer and Communications**, Scientific Research Publishing, v. 11, n. 9, p. 57–75, 2023.

FENU *et al.* Using multioutput learning to diagnose plant disease and stress severity. **Complexity**, Hindawi Limited, v. 2021, p. 1–11, 2021.

FERNÁNDEZ-CAMPOS, Mariela *et al.* Wheat spike blast image classification using deep convolutional neural networks. **Frontiers in Plant Science**, Frontiers Media SA, v. 12, p. 673505, 2021.

FLOOD, Julie. The importance of plant health to food security. **Food Security**, v. 2, n. 3, p. 215–231, 2010.

FONTEM, DA. Quantitative effects of early and late blights on tomato yields in Cameroon. **Tropicultura**, AGCD-BRUXELLES, v. 21, n. 1, p. 36–41, 2003.

FOOLAD, Majid R. *et al.* Genetics, Genomics and Breeding of Late Blight and Early Blight Resistance in Tomato. **Critical Reviews in Plant Sciences**, v. 27, p. 107–75, 2008. Disponível em: <https://api.semanticscholar.org/CorpusID:86191316>.

GAO, Junfeng *et al.* Automatic late blight lesion recognition and severity quantification based on field imagery of diverse potato genotypes by deep learning. **Knowledge-Based Systems**, Elsevier, v. 214, p. 106723, 2021.

GENG *et al.* Survey of recent progress in semantic image segmentation with CNNs. **Science China Information Sciences**, Springer, v. 61, p. 1–18, 2018.

GIRSHICK, Ross. Fast r-cnn. *In: PROCEEDINGS of the IEEE international conference on computer vision*. [S. l.: s. n.], 2015. p. 1440–1448.

GIRSHICK, Ross *et al.* Rich feature hierarchies for accurate object detection and semantic segmentation. *In: PROCEEDINGS of the IEEE conference on computer vision and pattern recognition*. [S. l.: s. n.], 2014. p. 580–587.

GONCALVES, J.P. *et al.* Deep learning architectures for semantic segmentation and automatic estimation of severity of foliar symptoms caused by diseases or pests. **Biosystems Engineering**, Elsevier, v. 210, p. 129–142, 2021.

GOODFELLOW *et al.* **Deep learning**. [S. l.]: MIT press, 2016.

GOODFELLOW, Ian *et al.* Generative adversarial nets. **Advances in neural information processing systems**, v. 27, 2014.

GOSHIKA, Sandeep *et al.* Deep Learning Model for classifying and evaluating soybean leaf disease damage. **International Journal of Molecular Sciences**, MDPI, v. 25, n. 1, p. 106, 2023.

GUYATT, Gordon; RENNIE, Drummond. Users' guides to the medical literature: essentials of evidence-based clinical practice. **(No Title)**, 2003.

HAMED *et al.* A Review of CNN-Based Techniques for Accurate Plant Disease Detection. **IJCI. International Journal of Computers and Information**, Minufiya University; Faculty of Computers e Information, 2023.

HAMILA, Oumaima *et al.* Fusarium head blight detection, spikelet estimation, and severity assessment in wheat using 3D convolutional neural networks. **Canadian Journal of Plant Science**, Canadian Science Publishing 1840 Woodward Drive, Suite 1, Ottawa, ON K2C 0P7, 2024.

HAN, and others. A new image classification method using CNN transfer learning and web data augmentation. **Expert Systems with Applications**, Elsevier, v. 95, p. 43–56, 2018.

HAQUE, Md Ashraful *et al.* A lightweight convolutional neural network for recognition of severity stages of maydis leaf blight disease of maize. **Frontiers in Plant Science**, Frontiers, v. 13, p. 1077568, 2022.

HAYIT, and others. Determination of the severity level of yellow rust disease in wheat by using convolutional neural networks. **Journal of Plant Pathology**, Springer, v. 103, n. 3, p. 923–934, 2021.

HAYIT, Tolga; ENDES, Ali; HAYIT, Fatma. The severity level classification of Fusarium wilt of chickpea by pre-trained deep learning models. **Journal of Plant Pathology**, Springer, v. 106, n. 1, p. 93–105, 2024.

HE, Kaiming; GKIOXARI, Georgia *et al.* Mask r-cnn. *In: PROCEEDINGS of the IEEE international conference on computer vision*. [S. l.: s. n.], 2017. p. 2961–2969.

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

HE, Kaiming; ZHANG, Xiangyu *et al.* Spatial pyramid pooling in deep convolutional networks for visual recognition. **IEEE transactions on pattern analysis and machine intelligence**, IEEE, v. 37, n. 9, p. 1904–1916, 2015.

HOWARD, Andrew G *et al.* Mobilenets: Efficient convolutional neural networks for mobile vision applications. **arXiv preprint arXiv:1704.04861**, 2017.

HU, Gensheng *et al.* Detection and severity analysis of tea leaf blight based on deep learning. **Computers & Electrical Engineering**, Elsevier, v. 90, p. 107023, 2021.

HUANG, Gao *et al.* Densely connected convolutional networks. *In: PROCEEDINGS of the IEEE conference on computer vision and pattern recognition*. [S. l.: s. n.], 2017. p. 4700–4708.

LANDOLA, Forrest N *et al.* SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size. **arXiv preprint arXiv:1602.07360**, 2016.

IIDUKA, Hideaki. Appropriate Learning Rates of Adaptive Learning Rate Optimization Algorithms for Training Deep Neural Networks. **IEEE Transactions on Cybernetics**, v. 52, p. 13250–13261, 2020. Disponível em: <https://api.semanticscholar.org/CorpusID:211259252>.

ILYAS, Talha *et al.* DIANA: A deep learning-based paprika plant disease and pest phenotyping system with disease severity analysis. **Frontiers in Plant Science**, Frontiers, v. 13, p. 983625, 2022.

IRVINE, John M.; ISRAEL, Steven A. Configuring CNN architectures for performance. *In: DEFENSE + Commercial Sensing*. [S. l.: s. n.], 2022. Disponível em: <https://api.semanticscholar.org/CorpusID:249144499>.

JACKULIN *et al.* A comprehensive review on detection of plant disease using machine learning and deep learning approaches. **Measurement: Sensors**, Elsevier, p. 100441, 2022.

JAIN, Charvi *et al.* Image Captioning Using CNN Long Short-Term Memory Network. *In: disponível em: https://api.semanticscholar.org/CorpusID:229592268*.

JEPKOECH, Jennifer *et al.* The Effect of Adaptive Learning Rate on the Accuracy of Neural Networks. **International Journal of Advanced Computer Science and Applications**, 2021. Disponível em: <https://api.semanticscholar.org/CorpusID:239463502>.

JI, Miaomiao; WU, Zhibin. Automatic detection and severity analysis of grape black measles disease based on deep learning and fuzzy logic. **Computers and Electronics in Agriculture**, Elsevier, v. 193, p. 106718, 2022.

JI, Miaomiao; ZHANG, Keke *et al.* Multi-label learning for crop leaf diseases recognition and severity estimation based on convolutional neural networks. **Soft Computing**, Springer, v. 24, p. 15327–15340, 2020.

JIA, Yuening. Attention Mechanism in Machine Translation. **Journal of Physics: Conference Series**, IOP Publishing, v. 1314, n. 1, p. 012186, out. 2019. DOI: 10 . 1088/1742-6596/1314/1/012186. Disponível em: <https://dx.doi.org/10.1088/1742-6596/1314/1/012186>.

JOSEPH *et al.* Intelligent plant disease diagnosis using convolutional neural network: a review. **Multimedia Tools and Applications**, Springer, v. 82, n. 14, p. 21415–21481, 2023.

KALOURIS, and others. Improving CNN-based activity recognition by data augmentation and transfer learning. *In: IEEE. 2019 IEEE 17th International Conference on Industrial Informatics (INDIN). [S. l.: s. n.], 2019. v. 1, p. 1387–1394.*

KEBEDE, Metiku *et al.* Impact of managing yellow rust (*Puccinia striiformis* f.sp. tritici) by the use of fungicide sprays and resistant varieties on the physiochemical qualities of bread wheat. **Food and Energy Security**, 2024. Disponível em: <https://api.semanticscholar.org/CorpusID:267483843>.

KEELE, Staffs *et al.* **Guidelines for performing systematic literature reviews in software engineering**. Durham, 2007.

KHAKIMOV, Albert *et al.* Traditional and current-prospective methods of agricultural plant diseases detection: A review. *In: IOP PUBLISHING, 1. IOP Conference series: earth and environmental science. [S. l.: s. n.], 2022. v. 951, p. 012002.*

KIHORO, Joseph *et al.* Investigating the impact of rice blast disease on the livelihood of the local farmers in greater Mwea region of Kenya. **SpringerPlus**, v. 2, 2013. Disponível em: <https://api.semanticscholar.org/CorpusID:16339307>.

KINGMA *et al.* Adam: A method for stochastic optimization. **arXiv preprint arXiv:1412.6980**, 2014.

KONAR, Jinia *et al.* Comparison of Various Learning Rate Scheduling Techniques on Convolutional Neural Network. **2020 IEEE International Students' Conference on Electrical, Electronics and Computer Science (SCEECS)**, p. 1–5, 2020. Disponível em: <https://api.semanticscholar.org/CorpusID:218564999>.

KRIZHEVSKY *et al.* Imagenet classification with deep convolutional neural networks. **Advances in neural information processing systems**, v. 25, 2012.

KUMAR, Deepak; KUKREJA, Vinay. Combined CNN with STARGAN for Wheat Yellow Rust Disease Classification. **International Journal of Computing and Digital Systems**, University of Bahrain, 2023.

KUMARI, Saumya *et al.* Application of Advance Deep Learning Models For Plant Disease Detection. **2024 International Conference on Integrated Circuits and Communication Systems (ICICACS)**, p. 1–6, 2024. Disponível em: <https://api.semanticscholar.org/CorpusID:269242039>.

LAMBA, Shweta *et al.* An ensemble (CNN-LSTM) model for severity detection of bacterial blight rice disease. *In: MOBILE Radio Communications and 5G Networks: Proceedings of Third MRCN 2022*. [S. l.]: Springer, 2023. p. 159–171.

LAMBA KUKREJA, Vinay *et al.* A novel hybrid severity prediction model for blast paddy disease using machine learning. **Sustainability**, MDPI, v. 15, n. 2, p. 1502, 2023.

LECUN, Yann *et al.* Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, Ieee, v. 86, n. 11, p. 2278–2324, 1998.

LI *et al.* Focus nuance and toward diversity: exploring domain-specific fine-grained few-shot recognition. **Neural Computing and Applications**, Springer, v. 35, n. 28, p. 21275–21290, 2023.

LIANG, Qiaokang *et al.* PD2SE-Net: Computer-assisted plant disease diagnosis and severity estimation network. **Computers and electronics in agriculture**, Elsevier, v. 157, p. 518–529, 2019.

LIN, Ke *et al.* Deep learning-based segmentation and quantification of cucumber powdery mildew using convolutional neural network. **Frontiers in Plant Science**, v. 10, p. 155, 2019.

LIU *et al.* Crop disease recognition based on modified light-weight CNN with attention mechanism. **IEEE Access**, IEEE, v. 10, p. 112066–112075, 2022.

LIU, Wei *et al.* Ssd: Single shot multibox detector. *In: SPRINGER. COMPUTER Vision–ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part I 14*. [S. l.: s. n.], 2016. p. 21–37.

LIU, Weizhen *et al.* StripeRust-Pocket: A Mobile-Based Deep Learning Application for Efficient Disease Severity Assessment of Wheat Stripe Rust. **Plant Phenomics**, AAAS, v. 2024, p. 0201, 2024.

LIU, Bo-Yuan *et al.* Two-stage convolutional neural networks for diagnosing the severity of alternaria leaf blotch disease of the apple tree. **Remote Sensing**, MDPI, v. 14, n. 11, p. 2519, 2022.

LIU, Ze *et al.* Swin transformer: Hierarchical vision transformer using shifted windows. *In: PROCEEDINGS of the IEEE/CVF international conference on computer vision*. [S. l.: s. n.], 2021. p. 10012–10022.

LONG *et al.* Fully convolutional networks for semantic segmentation. *In: PROCEEDINGS of the IEEE conference on computer vision and pattern recognition*. [S. l.: s. n.], 2015. p. 3431–3440.

LU, Jinzhu; TAN, Li; JIANG, Huanyu. Review on Convolutional Neural Network (CNN) Applied to Plant Leaf Disease Classification. **Agriculture**, 2021. Disponível em: <https://api.semanticscholar.org/CorpusID:237651665>.

LUCERO, Charles; QU, Guangzhi. Effects Analysis of Architecture Changes to Convolutional Neural Networks. **2017 13th International Conference on Semantics, Knowledge and Grids (SKG)**, p. 98–105, 2017. Disponível em: <https://api.semanticscholar.org/CorpusID:24677172>.

LYU *et al.* Multi-vehicle tracking based on monocular camera in driver view. **Applied Sciences**, MDPI, v. 12, n. 23, p. 12244, 2022.

AL-MAAROOF, Emad Mahmood. Effect of yellow rust disease on quantitative and qualitative traits of some wheat genotypes under rain-fed conditions. **Journal of Applied Biological Sciences**, v. 13, n. 2, p. 75–83, 2019.

MABROUK, Ola Ibrahim *et al.* The Impact of Wheat Yellow Rust on Quantitative and Qualitative Grain Yield Losses under Egyptian Field Conditions. **Egyptian Journal of Phytopathology**, 2022. Disponível em: <https://api.semanticscholar.org/CorpusID:247397120>.

MADDEN, and others. **The study of plant disease epidemics**. St. Paul, MN: APS Press, 2007.

MAIRAL, Julien *et al.* Convolutional Kernel Networks. **ArXiv**, abs/1406.3332, 2014. Disponível em: <https://api.semanticscholar.org/CorpusID:8171616>.

MARTINS, Mônica C *et al.* Escala diagramática para a quantificação do complexo de doenças foliares de final de ciclo em soja. **Fitopatologia Brasileira**, SciELO Brasil, v. 29, p. 179–184, 2004.

MASTERS *et al.* Revisiting small batch training for deep neural networks. **arXiv preprint arXiv:1804.07612**, 2018.

MATHIEU, Laura *et al.* SeptoSympto: a precise image analysis of Septoria tritici blotch disease symptoms using deep learning methods on scanned images. **Plant Methods**, Springer, v. 20, n. 1, p. 18, 2024.

MENON, Vishal *et al.* Plant Disease Detection using CNN and Transfer Learning. **2021 International Conference on Communication, Control and Information Sciences (ICCISc)**, v. 1, p. 1–6, 2021. Disponível em: <https://api.semanticscholar.org/CorpusID:236191810>.

MOHAMETH *et al.* Plant disease detection with deep learning and feature extraction using plant village. **Journal of Computer and Communications**, Scientific Research Publishing, v. 8, n. 6, p. 10–22, 2020.

MUDGIL, Rishabh *et al.* Identification of Tomato Plant Diseases Using CNN-A Comparative Review. *In*: IEEE. 2022 IEEE World Conference on Applied Intelligence and Computing (AIC). [*S. l.: s. n.*], 2022. p. 174–181.

NAGARAJU, and others. Systematic review of deep learning techniques in plant disease detection. **International journal of system assurance engineering and management**, Springer, v. 11, p. 547–560, 2020.

NAIR *et al.* Rectified linear units improve restricted boltzmann machines. *In*: PROCEEDINGS of the 27th international conference on machine learning (ICML-10). [*S. l.: s. n.*], 2010. p. 807–814.

NATESAN, Balaji *et al.* Channel–Spatial Segmentation Network for Classifying Leaf Diseases. **Agriculture**, MDPI, v. 12, n. 11, p. 1886, 2022.

NGUGI, and others. Recent advances in image processing techniques for automated leaf pest and disease recognition—A review. **Information processing in agriculture**, Elsevier, v. 8, n. 1, p. 27–51, 2021.

NOEL *et al.* Alternate Loss Functions for Classification and Robust Regression Can Improve the Accuracy of Artificial Neural Networks. **arXiv preprint arXiv:2303.09935**, 2023.

NOH, Tae-Hwan *et al.* Effects of Bacterial Leaf Blight Occurrence on Rice Yield and Grain Quality in Different Rice Growth Stage. **Radiation Protection Dosimetry**, v. 13, p. 20–23, 2007. Disponível em: <https://api.semanticscholar.org/CorpusID:85114585>.

NOON, Serosh Karim *et al.* Handling severity levels of multiple co-occurring cotton plant diseases using improved YOLOX model. **IEEE Access**, IEEE, v. 10, p. 134811–134825, 2022.

PAL, Arunangshu; KUMAR, Vinay. AgriDet: Plant Leaf Disease severity classification using agriculture detection framework. **Engineering Applications of Artificial Intelligence**, Elsevier, v. 119, p. 105754, 2023.

PASSRICHA, Vishal; AGGARWAL, Rajesh Kumar. A Hybrid of Deep CNN and Bidirectional LSTM for Automatic Speech Recognition. **Journal of Intelligent Systems**, v. 29, p. 1261–1274, 2019. Disponível em: <https://api.semanticscholar.org/CorpusID:86766369>.

PATEL, Mitesh *et al.* ContextualNet: Exploiting Contextual Information Using LSTMs to Improve Image-Based Localization. **2018 IEEE International Conference on Robotics and Automation (ICRA)**, p. 1–7, 2018. Disponível em: <https://api.semanticscholar.org/CorpusID:3785076>.

PATIL, Rutuja Rajendra *et al.* An artificial-intelligence-based novel rice grade model for severity estimation of rice diseases. **Agriculture**, MDPI, v. 13, n. 1, p. 47, 2022.

PRABHAKAR, Maheswari; PURUSHOTHAMAN, Raja; AWASTHI, Durga Prasad. Deep learning based resolussment of disease severity for early blight in tomato crop. **Multimedia Tools and Applications**, Springer, v. 79, p. 28773–28784, 2020.

PURWONO, Purwono *et al.* Understanding of Convolutional Neural Network (CNN): A Review. **International Journal of Robotics and Control Systems**, 2023. Disponível em: <https://api.semanticscholar.org/CorpusID:258029303>.

QU, Hongchun *et al.* A deep multi-task learning approach to identifying mummy berry infection sites, the disease stage, and severity. **Frontiers in Plant Science**, Frontiers Media SA, v. 15, p. 1340884, 2024.

RAJASREE, R; LATHA, C Beulah Christalin. Improved YOLO-X Model for Tomato Disease Severity Detection using Field Dataset. **International Journal of Advanced Computer Science and Applications**, Science e Information (SAI) Organization Limited, v. 14, n. 9, 2023.

RAJPAL *et al.* Multi-resolution analysis and deep neural network architecture based hybrid feature extraction technique for plant disease identification and severity estimation. **Evolutionary Intelligence**, Springer, p. 1–21, 2022.

RAMCHARAN, Amanda *et al.* A mobile-based deep learning model for cassava disease diagnosis. **Frontiers in plant science**, Frontiers, v. 10, p. 425916, 2019.

REDMON, Joseph *et al.* You only look once: Unified, real-time object detection. *In: PROCEEDINGS of the IEEE conference on computer vision and pattern recognition*. [S. l.: s. n.], 2016. p. 779–788.

REN, Shaoqing *et al.* Faster r-cnn: Towards real-time object detection with region proposal networks. **Advances in neural information processing systems**, v. 28, 2015.

RHANOUI, Maryem *et al.* A CNN-BiLSTM Model for Document-Level Sentiment Analysis. **Mach. Learn. Knowl. Extr.**, v. 1, p. 832–847, 2019. Disponível em: <https://api.semanticscholar.org/CorpusID:199589696>.

RONNEBERGER *et al.* U-net: Convolutional networks for biomedical image segmentation. *In: SPRINGER. MEDICAL Image Computing and Computer-Assisted Intervention–MICCAI 2015: 18th International Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III* 18. [S. l.: s. n.], 2015. p. 234–241.

SABOUR *et al.* Dynamic routing between capsules. **Advances in neural information processing systems**, v. 30, 2017.

SAHA, Poly; DAS, Srikanta. Assessment of Yield Loss Due to Early Blight (*Alternaria solani*) in Tomato. **Indian Journal of Plant Protection**, v. 40, p. 195–198, 2012. Disponível em: <https://api.semanticscholar.org/CorpusID:74699385>.

SANDLER, Mark *et al.* Mobilenetv2: Inverted residuals and linear bottlenecks. *In: PROCEEDINGS of the IEEE conference on computer vision and pattern recognition*. [S. l.: s. n.], 2018. p. 4510–4520.

SATTARI, Ali *et al.* Leaf blight resistance in rice: a review of breeding and biotechnology. **International Journal of Farming and Allied Sciences**, v. 3, n. 8, p. 895–902, 2014.

SCHERER *et al.* Evaluation of pooling operations in convolutional architectures for object recognition. *In: SPRINGER. INTERNATIONAL conference on artificial neural networks*. [S. l.: s. n.], 2010. p. 92–101.

SCHINDELIN, Johannes *et al.* Fiji: an open-source platform for biological-image analysis. **Nature Methods**, v. 9, n. 7, p. 676–682, jul. 2012. ISSN 1548-7105. DOI: 10 . 1038/nmeth.2019. Disponível em: <https://doi.org/10.1038/nmeth.2019>.

SCHNEIDER *et al.* NIH Image to ImageJ: 25 years of image analysis. **Nature Methods**, v. 9, n. 7, p. 671–675, jul. 2012. ISSN 1548-7105. DOI: 10 . 1038/nmeth.2089. Disponível em: <https://doi.org/10.1038/nmeth.2089>.

SHEKHAR, Sumit *et al.* An Overview of Bacterial Leaf Blight Disease of Rice and Different Strategies for its Management. **International Journal of Current Microbiology and Applied Sciences**, v. 9, p. 2250–2265, 2020. Disponível em: <https://api.semanticscholar.org/CorpusID:219650550>.

SHI, Tingting *et al.* Recent advances in plant disease severity resoluishment using convolutional neural networks. **Scientific Reports**, Nature Publishing Group UK London, v. 13, n. 1, p. 2336, 2023.

SHOAIB, Muhammad Ali *et al.* A deep learning-based model for plant lesion segmentation, subtype identification, and survival probability estimation. **Frontiers in Plant Science**, v. 13, 2022. Disponível em: <https://api.semanticscholar.org/CorpusID:254641019>.

SHORTEN *et al.* A survey on image data augmentation for deep learning. **Journal of big data**, SpringerOpen, v. 6, n. 1, p. 1–48, 2019.

SHRESTHA, Garima *et al.* Plant Disease Detection Using CNN. **2020 IEEE Applied Signal Processing Conference (ASPCON)**, p. 109–113, 2020. Disponível em: [http s://api.semanticscholar.org/CorpusID:228094232](http://s://api.semanticscholar.org/CorpusID:228094232).

SHRUTHI, U; NAGAVENI, V. TomSevNet: a hybrid CNN model for accurate tomato disease identification with severity level assessment. **Neural Computing and Applications**, Springer, p. 1–17, 2023.

SIBIYA, Malusi; SUMBWANYAMBE, Mbuyu. Automatic fuzzy logic-based maize common rust disease severity predictions with thresholding and deep learning. **Pathogens**, MDPI, v. 10, n. 2, p. 131, 2021.

SIMONYAN *et al.* Very deep convolutional networks for large-scale image recognition. **arXiv preprint arXiv:1409.1556**, 2014.

SINGH, Arti *et al.* Machine learning for high-throughput stress phenotyping in plants. **Trends in plant science**, Elsevier, v. 21, n. 2, p. 110–124, 2016.

SOKOLOVA, Marina; LAPALME, Guy. A systematic analysis of performance measures for classification tasks. **Information processing & management**, Elsevier, v. 45, n. 4, p. 427–437, 2009.

SREEDEVI, Alampally; MANIKE, Chiranjeevi. A smart solution for tomato leaf disease classification by modified recurrent neural network with severity computation. **Cybernetics and Systems**, Taylor & Francis, v. 55, n. 2, p. 409–449, 2024.

SRIVASTAVA, Nitish *et al.* Dropout: a simple way to prevent neural networks from overfitting. **The journal of machine learning research**, JMLR. org, v. 15, n. 1, p. 1929–1958, 2014.

SU, Wen-Hao *et al.* Automatic evaluation of wheat resistance to fusarium head blight using dual mask-RCNN deep learning frameworks in computer vision. **Remote sensing**, MDPI, v. 13, n. 1, p. 26, 2020.

SUGANYA, J *et al.* Early Detection and Classification of Plant Diseases/Abiotic Disorders using Deep Learning-A Review. *In:* IEEE. 2022 4th International Conference on Inventive Research in Computing Applications (ICIRCA). [*S. l.: s. n.*], 2022. p. 646–655.

SZEGEDY, Christian *et al.* Going deeper with convolutions. *In:* PROCEEDINGS of the IEEE conference on computer vision and pattern recognition. [*S. l.: s. n.*], 2015. p. 1–9.

TAN, Mingxing; LE, Quoc. Efficientnet: Rethinking model scaling for convolutional neural networks. *In:* PMLR. INTERNATIONAL conference on machine learning. [*S. l.: s. n.*], 2019. p. 6105–6114.

THENAPPAN *et al.* Wheat leaf diseases classification and severity analysis using HT-CNN and Hex-D-VCC-based boundary tracing mechanism. **Environmental Monitoring and Assessment**, Springer, v. 195, n. 12, p. 1505, 2023.

TIXIER, Antoine J.-P. Introduction to CNNs and LSTMs for NLP. *In:* disponível em: <https://api.semanticscholar.org/CorpusID:4117568>.

TODA, Yosuke; OKURA, Fumio. How convolutional neural networks diagnose plant disease. **Plant Phenomics**, AAAS, 2019.

UPADHYAY, Santosh Kumar; KUMAR, Avadhesh. Early-Stage Brown Spot Disease Recognition in Paddy Using Image Processing and Deep Learning Techniques. **Traitement du Signal**, v. 38, n. 6, 2021.

VASWANI, Ashish *et al.* Attention is all you need. **Advances in neural information processing systems**, v. 30, 2017.

VERMA, and others. Deep learning-based mobile application for plant disease diagnosis: A proof of concept with a case study on tomato plant. *In:* APPLICATIONS of image processing and soft computing systems in agriculture. [*S. l.*]: IGI global, 2019. p. 242–271.

VERMA, Shradha; CHUG, Anuradha; SINGH, Amit Prakash; SINGH, Dinesh. PDS-MCNet: a hybrid framework using MobileNetV2 with SiLU6 activation function and capsule networks for disease severity estimation in plants. **Neural Computing and Applications**, Springer, p. 1–24, 2023.

VERMA, Shradha; CHUG, Anuradha; SINGH, Amit Prakash; SINGH, Dinesh. Plant Disease Detection and Severity Assessment Using Image Processing and Deep Learning Techniques. **SN Computer Science**, Springer, v. 5, n. 1, p. 83, 2023.

VERMA, Shradha; CHUG, Anuradha; SINGH, Ravinder P; SINGH, Amit P; SINGH, Dinesh. SE-CapsNet: Automated evaluation of plant disease severity based on feature extraction through Squeeze and Excitation (SE) networks and Capsule networks. **Kuwait Journal of Science**, v. 49, n. 1, 2022.

VOS, Etienne E *et al.* Long-range seasonal forecasting of 2m-temperature with machine learning. **arXiv preprint arXiv:2102.00085**, 2021.

WANG *et al.* Automatic image-based plant disease severity estimation using deep learning. **Computational intelligence and neuroscience**, Hindawi, v. 2017, 2017.

WANG, Chunshan *et al.* A cucumber leaf disease severity classification method based on the fusion of DeepLabV3+ and U-Net. **Computers and Electronics in Agriculture**, Elsevier, v. 189, p. 106373, 2021.

WANG, Hanlin *et al.* Area localization of leaf diseases under complex environments. *In: SPIE. THIRD International Conference on Advanced Algorithms and Signal Image Processing (AASIP 2023)*. [*S. l.: s. n.*], 2023. v. 12799, p. 484–489.

WANG, Kafeng *et al.* Pay attention to features, transfer learn faster CNNs. *In: INTERNATIONAL conference on learning representations*. [*S. l.: s. n.*], 2019.

WANG, Xin *et al.* Identification of tomato bacterial wilt severity based on hyperspectral imaging technology and spectrum Transformer network. **Ecological Informatics**, Elsevier, v. 78, p. 102353, 2023.

WANG, Xueying *et al.* Diagnosis of soybean bacterial blight progress stage based on deep learning in the context of data-deficient. **Computers and Electronics in Agriculture**, Elsevier, v. 212, p. 108170, 2023.

WANG, Yafei *et al.* Cucumber Downy Mildew Disease Prediction Using a CNN-LSTM Approach. **Agriculture**, MDPI, v. 14, n. 7, p. 1155, 2024.

WAQAS *et al.* Assessment of Advanced Artificial Intelligence Techniques for Flood Forecasting. *In: IEEE. 2023 International Multi-disciplinary Conference in Emerging Research Trends (IMCERT)*. [*S. l.: s. n.*], 2023. v. 1, p. 1–6.

WAQAS *et al.* Potential of artificial intelligence-based techniques for rainfall forecasting in Thailand: A comprehensive review. **Water**, MDPI, v. 15, n. 16, p. 2979, 2023.

WIEBE, Keith *et al.* Modeling impacts of faster productivity growth to inform the CGIAR initiative on Crops to End Hunger. **PLoS ONE**, v. 16, 2020. Disponível em: <https://api.semanticscholar.org/CorpusID:226428112>.

WOO *et al.* Cbam: Convolutional block attention module. *In: PROCEEDINGS of the European conference on computer vision (ECCV)*. [S. l.: s. n.], 2018. p. 3–19.

XIANG, Shao *et al.* L-CSMS: novel lightweight network for plant disease severity recognition. **Journal of Plant Diseases and Protection**, Springer, v. 128, p. 557–569, 2021.

XU, Yanlei *et al.* A Two-Stage Approach to the Study of Potato Disease Severity Classification. **Agriculture**, MDPI, v. 14, n. 3, p. 386, 2024.

YAKKUNDIMATH *et al.* Identification of paddy blast disease field images using multi-layer CNN models. **Environmental Monitoring and Assessment**, Springer, v. 195, n. 6, p. 646, 2023.

YAMASHITA, Rikiya *et al.* Convolutional neural networks: an overview and application in radiology. **Insights into Imaging**, v. 9, p. 611–629, 2018. Disponível em: <https://api.semanticscholar.org/CorpusID:49389393>.

YANG, Bin; LI, Mingwei *et al.* A novel plant type, leaf disease and severity identification framework using CNN and transformer with multi-label method. **Scientific Reports**, Nature Publishing Group UK London, v. 14, n. 1, p. 11664, 2024.

YANG, Bin; WANG, Zhulian *et al.* Identifying plant disease and severity from leaves: A deep multitask learning framework using triple-branch Swin Transformer and deep supervision. **Computers and Electronics in Agriculture**, Elsevier, v. 209, p. 107809, 2023.

YOSINSKI, Jason *et al.* How transferable are features in deep neural networks? **Advances in neural information processing systems**, v. 27, 2014.

ZENG, Qingmao *et al.* Gans-based data augmentation for citrus disease severity detection using deep learning. **IEEE Access**, IEEE, v. 8, p. 172882–172891, 2020.

ZHANG, Tianxiang *et al.* Wheat yellow rust severity detection by efficient DF-UNet and UAV multispectral imagery. **IEEE Sensors Journal**, IEEE, v. 22, n. 9, p. 9057–9068, 2022.

ZHANG, Xiangyu *et al.* Shufflenet: An extremely efficient convolutional neural network for mobile devices. *In: PROCEEDINGS of the IEEE conference on computer vision and pattern recognition*. [S. l.: s. n.], 2018. p. 6848–6856.

ZHAO, Hengshuang *et al.* Pyramid scene parsing network. *In: PROCEEDINGS of the IEEE conference on computer vision and pattern recognition*. [S. l.: s. n.], 2017. p. 2881–2890.

ZHAO, Kai *et al.* Object Detection: Training From Scratch. **IEEE Access**, v. 8, p. 157520–157529, 2020. Disponível em: <https://api.semanticscholar.org/CorpusID:221568002>.

CAPÍTULO II

MODELOS DE APRENDIZADO PROFUNDO PARA DETECÇÃO E AVALIAÇÃO DE SEVERIDADE DA MANCHA DE CERCOSPORA (CERCOSPORA CAPSICI) EM PIMENTAS SOB CONDIÇÕES NATURAIS²

RESUMO

Determinar a severidade das doenças das plantas é crucial para uma gestão agrícola eficaz e para a prevenção de perdas nas culturas. As tecnologias de aprendizado profundo, particularmente as redes neurais convolucionais - *Convolutional Neural Networks* (CNNs), têm sido cada vez mais aplicadas em tarefas de segmentação de imagens, incluindo a detecção de lesões em plantas. Este estudo compara o desempenho de oito modelos baseados em duas abordagens—YOLOv8, um modelo baseado em uma etapa, e Mask R-CNN, um modelo de duas etapas—na segmentação e determinação automática da severidade da cercosporiose em folhas de pimenta malagueta. Um conjunto de dados personalizado foi coletado, composto por folhas saudáveis e doentes com variabilidade nas condições de plano de fundo e iluminação. Os modelos foram avaliados em diferentes limiares de confiança - *Confidence Threshold* (CT) para avaliar a robustez e precisão. Os resultados indicaram que os modelos treinados apresentaram bom desempenho, com valores de mAP50 de segmentação variando de 0,893 a 0,925 no conjunto de validação. Em avaliações de nível de pixel no conjunto de teste, o Mask R-CNN superou o YOLOv8, alcançando um maior Índice Médio de Interseção sobre União (MIoU) e F1-score de 0,860 e 0,924, respectivamente, para o modelo mask_rcnn_R101_FPN_3x, em comparação com 0,808 e 0,893 para o modelo YOLOv8s-Seg. Quanto à classificação do nível de severidade, os modelos Mask R-CNN geraram máscaras preditivas menores que as reais, levando à subestimação da severidade e uma tendência a sub-classificar os níveis de severidade mais altos. Nesse cenário, o desempenho do Mask R-CNN caiu para 72,3% no nível de severidade III, enquanto o YOLO alcançou 91,4%. Os modelos YOLOv8 demonstraram clara superioridade no tempo de inferência, com o melhor tempo médio de inferência de 27 ms em comparação com 89 ms para o Mask R-CNN. Esses resultados sugerem que, dado

seu tempo de inferência mais rápido e desempenho confiável na classificação de severidade, o YOLOv8 pode ser mais adequado para aplicações no mundo real na avaliação de doenças das plantas.

Palavras-chave: Redes Neurais Convolucionais; CNN, severidade de doenças em plantas; cercosporiose

² Trabalho publicado na revista *Plants*, ISSN: 2223-7747, Volume 14, Issue 13, 2025, JCR 2025: 4,1.
DOI: <https://doi.org/10.3390/plants14132011>

DEEP LEARNING MODELS FOR DETECTION AND SEVERITY ASSESSMENT OF CERCOSPORA LEAF SPOT (CERCOSPORA CAPSICI) IN CHILI PEPPERS UNDER NATURAL CONDITIONS

ABSTRACT

Determining plant disease severity is crucial for effective agricultural management and preventing crop losses. Deep learning technologies, particularly Convolutional Neural Networks (CNNs), have been increasingly applied in image segmentation tasks, including plant lesion detection. This study compares the performance of eight models based on two approaches—YOLOv8, a single-stage model, and Mask R-CNN, a two-stage model—in the segmentation and automatic determination of cercospora leaf spot severity in malagueta pepper leaves. A custom dataset was collected, composed of healthy and diseased leaves with variability in background and lighting conditions. The models were evaluated at different confidence thresholds (CT) to assess robustness and accuracy. Results indicated that the trained models showed good performance, with segmentation mAP50 values ranging from 0.893 to 0.925 on the validation set. In pixel-level evaluations on the test set, Mask R-CNN outperformed YOLOv8, achieving higher Mean Intersection over Union (MIoU) and F1-score of 0.860 and 0.924, respectively, for the mask_rcnn_R101_FPN_3x model, compared to 0.808 and 0.893 for the YOLOv8s-Seg model. Regarding severity level classification, Mask R-CNN models generated smaller predictive masks than the real ones, leading to severity underestimation and a tendency to sub-classify higher severity levels. In this scenario, Mask R-CNN performance dropped to 72.3% at severity level III, while YOLO achieved 91.4%. YOLOv8 models demonstrated clear superiority in inference time, with the best average inference time of 27 ms compared to 89 ms for Mask R-CNN. These results suggest that, given its faster inference time and reliable performance in severity classification, YOLOv8 may be more suitable for real-world applications in plant disease assessment.

Keywords: Convolutional Neural Networks; CNN, plant disease severity; cercospora leaf spot

1 Introdução

As doenças de plantas representam uma ameaça significativa à agricultura global, resultando em perdas econômicas substanciais estimadas em 220 bilhões de dólares anualmente, impactando o rendimento das colheitas, a qualidade e a segurança alimentar (Gold, 2021; Wilson, 2016). Determinar a severidade das doenças de plantas é essencial para um manejo eficaz das colheitas, previsão de perdas de rendimento e controle das doenças. Também ajuda a evitar aplicações químicas desnecessárias, reduzindo assim os riscos à saúde e ao meio ambiente (Daminda Thushara Andrahannadi, 2020; Bock *et al.*, 2020).

As pimentas, especialmente as espécies *Capsicum*, têm importância econômica e cultural no Brasil. São valorizados pelo uso culinário, propriedades nutricionais e relevância na agricultura familiar (Trecha, 2017). As pimentas brasileiras apresentam diversas composições bioquímicas, incluindo capsaicinoides, compostos fenólicos e antioxidantes, que variam dependendo da espécie, do ponto de maturação e do ano de colheita (Bogusz *et al.*, 2018; Gomes *et al.*, 2019). O cultivo de pimenta no Brasil enfrenta desafios, como o uso excessivo de pesticidas (Trecha, 2017). Uma das doenças que afeta significativamente esse cultivo é a cercosporiose, uma doença fúngica destrutiva que afeta diversas culturas, incluindo beterraba açucareira, rosas, trigo e pimentão (Rangel *et al.*, 2020; Weiland; Koch, 2004). Ela causa lesões circulares nas folhas, levando à desfolhação e perdas de rendimento, tornando a avaliação precisa da severidade da doença crucial para um manejo eficaz (Weiland; Koch, 2004).

As técnicas tradicionais de processamento digital de imagens possibilitaram o desenvolvimento de métodos para determinar a severidade das doenças de plantas. Esses métodos dependem da captura de imagens de plantas afetadas e da análise computacional das características visuais das lesões ou sintomas (Singh *et al.*, 2016). Softwares como ImageJ (Schneider *et al.*, 2012), Assess2 e Fiji (Schindelin *et al.*, 2012) têm sido usados para manipulação de imagens e obtenção de dados sobre áreas de folhas e lesões. No entanto, essas ferramentas ainda dependem da intervenção humana para determinar a cor correspondente à lesão, confundindo lesões não patológicas e subestimando a severidade devido à interpretação incorreta dos tons representando tecido doente (Amorim *et al.*, 2016).

Tecnologias automatizadas baseadas em sensores, incluindo processamento de imagens e aprendizado de máquina, especialmente CNNs, estão sendo cada vez mais desenvolvidas para melhorar a precisão e a eficiência (Faye *et al.*, 2023). As CNNs têm se mostrado altamente eficazes na detecção de doenças de plantas, demonstrando sua capacidade de extrair características simultaneamente e realizar a classificação em diversos estudos (Toda; Okura, 2019; Barburiceanu *et al.*, 2021). Ao longo dos anos, os modelos baseados em CNN alcançaram avanços significativos em classificação de imagens, detecção de objetos e segmentação de instâncias (Geng *et al.*, 2018).

A segmentação de instâncias é uma tarefa de visão computacional que combina detecção de objetos e segmentação semântica, com o objetivo de detectar, classificar e delimitar instâncias individuais de objetos em uma imagem (Hafiz; Bhat, 2020; Sharma, R. *et al.*, 2022). Esta técnica de aprendizado profundo tem surgido como uma ferramenta crítica para a agricultura de precisão, permitindo a detecção e localização precisa de culturas e ervas daninhas, bem como a identificação precisa da severidade de doenças em várias culturas (Charisis; Argyropoulos, 2024).

Atualmente, duas arquiteturas se destacam na segmentação de instâncias para a agricultura: Mask R-CNN e YOLO. Pesquisas recentes exploraram o uso do Mask R-CNN para detecção e segmentação de doenças na agricultura. Esta técnica de aprendizado profundo mostrou resultados promissores na identificação e segmentação de doenças em plantas, incluindo doenças de culturas de arroz (Sunanda, 2020), ferrugem nas folhas de maçã (Gary Storey, 2022) e oídio no trigo (Kumar; Kukreja, 2022). O Mask R-CNN também foi aplicado para detecção de doenças nas folhas de algodão (Udawant; Srinath, 2022) e reconhecimento de ervas daninhas (Valicharla, 2021).

Recentemente lançados para tarefas de segmentação de instâncias, os modelos YOLOv8 também foram aplicados para detecção e segmentação de doenças foliares em diversas plantas, incluindo tomates (Brucal *et al.*, 2023), arroz (Dong *et al.*, 2024) e trigo (Sharma, R. *et al.*, 2022). O modelo demonstrou um bom desempenho, alcançando taxas de precisão e recall acima de 95% em muitos casos (Qadri *et al.*, 2023; Sharma, J. *et al.*, 2024). Seu estilo de inferência de uma única etapa o torna atraente para aplicações no mundo real devido à sua velocidade.

Alguns estudos que comparam o desempenho dessas duas arquiteturas mostraram a superioridade do YOLOv8 sobre o Mask R-CNN em termos de precisão e velocidade de inferência em diversas aplicações, incluindo ambientes de pomares (Sapkota, 2023). Por outro lado, outros trabalhos demonstraram que o Mask R-CNN tem um desempenho semelhante ou até superior em alguns casos (Wang, N. *et al.*, 2023; Gentilhomme *et al.*, 2023; Kok, 2023).

Dado o uso do Mask R-CNN e YOLOv8 para tarefas de segmentação e a falta de estudos comparativos sobre essas ferramentas para determinar automaticamente a severidade das doenças das plantas, este estudo visa comparar sistematicamente essas duas estruturas. O foco está na avaliação do desempenho delas na detecção e determinação da severidade da cercosporiose nas folhas de pimenta utilizando um conjunto de dados personalizado. Esta comparação busca fornecer informações práticas sobre sua adequação, eficiência e desafios na aplicação desses modelos, orientando e guiando futuras pesquisas e aplicações na área.

Este artigo está organizado da seguinte forma: primeiro, uma seção teórica apresenta as características dos modelos de uma etapa (YOLOv8) e de duas etapas (Mask R-CNN). Em seguida, a seção "Materiais e Métodos" detalha o desenho experimental, os processos de aquisição de dados e as técnicas analíticas. Posteriormente, a seção "Resultados e

Discussão"apresenta e examina criticamente os resultados, com foco no desempenho dos modelos. A seção "Conclusão"resume os métodos de pesquisa e os resultados críticos do estudo. Por fim, a seção "Trabalhos Futuros"delineia possíveis direções para comparações adicionais com outros modelos de ponta.

2 Modelos de Aprendizado Profundo

2.1 YOLOv8

YOLO (You Only Look Once) (Jocher *et al.*, 2023), fornecido pela *Ultralytics*, é uma arquitetura de detecção de uma etapa que permite a localização, classificação e segmentação de objetos em uma única passagem pela rede. Os algoritmos YOLO revolucionaram a detecção de objetos ao equilibrar velocidade e precisão (Wang, X. *et al.*, 2023).


Anteriormente dedicados exclusivamente à detecção de objetos, os algoritmos YOLO expandiram para incluir tarefas de segmentação desde 2023 com os modelos YOLOv8-seg. Esta integração aproveita os princípios da rede YOLACT (Bolya *et al.*, 2019), permitindo a segmentação de instâncias no nível do pixel.

A arquitetura do YOLOv8-Seg (Figura 18) é construída em torno de vários componentes chave, começando com a espinha dorsal - *backbone*, que é responsável por extrair características complexas das imagens de entrada. O módulo C2f (*Context Fusion e Feature Fusion*) integra informações contextuais de diferentes camadas e escalas, aumentando o reconhecimento de objetos em cenas complexas. Enquanto isso, o módulo SPPF (*Spatial Pyramid Pooling Fast*) preserva a resolução espacial e captura informações contextuais em múltiplas escalas, melhorando a robustez da detecção de objetos.

O módulo *neck* conecta a *backbone* e a *head*, integrando Redes de Pirâmides de Características (FPNs) para enriquecer os mapas de características em diferentes escalas. A *head* gera as previsões finais, incluindo caixas delimitadoras, classes de objetos e máscaras de segmentação, usando caixas de ancoragem e células de grade. O módulo de uma única etapa gera máscaras de protótipo refinadas para uma segmentação precisa e uma delimitação aprimorada dos limites dos objetos. Etapas de pós-processamento são aplicados após o modelo fazer as previsões para refinar as saídas. Isso pode incluir Supressão de Não Máximos (NMS) para remover detecções duplicadas e limitação para filtrar previsões de baixa confiança.

De forma geral, o YOLOv8-Seg mantém a arquitetura fundamental do YOLO para detecção de objetos, ao mesmo tempo em que introduz um módulo adicional de saída na *head* para gerar coeficientes de máscara.

Figura 18 – Arquitetura do YOLOv8-Seg.



2.2 Mask R-CNN


Lançado, em sua primeira versão, pelo *Facebook AI Research* em 2019 (Wu *et al.*, 2019) como parte do framework Detectron2, o Mask R-CNN é um modelo de aprendizado profundo de última geração, renomado por sua versatilidade e eficácia em diversas tarefas de visão computacional (Rani; Arroyo; Durdevic, 2023). Construído sobre a biblioteca de aprendizado profundo *PyTorch*, o Mask R-CNN segue uma abordagem de duas etapas e apresenta quatro componentes principais: o *backbone*, o *neck*, a rede de proposta de região - *Region Proposal Network* (RPN) e o *head*.

Na primeira etapa, o backbone e o neck trabalham juntos para extrair e processar características da imagem de entrada. O backbone é responsável pela extração das características, utilizando diversas arquiteturas pré-treinadas como o ResNet. Essas arquiteturas, treinadas em grandes conjuntos de dados de imagens, como o ImageNet, permitem que o backbone aprenda representações ricas de características cruciais para as tarefas subsequentes. A rede backbone inclui várias camadas convolucionais organizadas hierarquicamente, capturando características em múltiplos níveis. O componente neck é implementado como uma FPN, que melhora as capacidades do backbone ao criar uma pirâmide de características em múltiplas escalas. A FPN combina características semânticas robustas de baixa resolução com características semânticas fracas de alta resolução por meio de um caminho top-down e conexões laterais, permitindo que a rede gere mapas de características robustos em várias escalas.

Na segunda etapa, a Rede de Proposta de Região (RPN) e o head refinam esses mapas de características para produzir as saídas finais. A RPN gera propostas de região com base nos mapas de características da FPN, identificando cerca de 1000 propostas de caixas que provavelmente contêm objetos. Isso é alcançado ao deslizar uma rede pequena sobre

os mapas de características e prever a pontuação de objetividade e as coordenadas da caixa delimitadora para cada ponto âncora. A RPN estreita eficientemente as regiões de interesse. Posteriormente, o componente head refina essas propostas de região e gera as máscaras de segmentação. Ele realiza classificações e regressões adicionais para ajustar as caixas delimitadoras e prevê máscaras binárias para cada objeto detectado. A Figura 19 mostra a arquitetura do Mask R-CNN.

Figura 19 – Arquitetura do Mask R-CNN.



3 Materiais e Métodos

O estudo compreendeu quatro etapas principais: coleta de dados, preparação do conjunto de dados, treinamento e avaliação de desempenho, conforme mostrado na Figura 20a. Inicialmente, foram capturadas imagens RGB das folhas de pimenta (*Capsicum Frutenscens*) em campo (Figura 20b), incluindo folhas saudáveis e afetadas pela cercosporiose (Figura 20c). As imagens foram capturadas sob condições naturais, com diferentes condições ambientais e de iluminação ao longo dos dias. Em seguida, as lesões nas folhas foram anotadas manualmente para criar os conjuntos de dados de treinamento e teste. O conjunto de dados de treinamento anotado foi então utilizado para treinar oito modelos correspondentes às arquiteturas Mask R-CNN e YOLOv8-Seg. Por fim, o desempenho dos modelos treinados foi avaliado utilizando o conjunto de dados de teste.

3.1 Aquisição do conjunto de dados (dataset) e preparação

O conjunto de dados é composto por imagens capturadas entre 15 de março de 2023 e 31 de maio de 2023, em uma plantação localizada em Lagarto, Estado de Sergipe, Brasil (Lat: -10.9145, Long: -37.6639) - Figura 20b. Um total de 1.645 imagens de folhas de pimenta malagueta foram coletadas. Todas as imagens foram registradas utilizando um *smartphone* com uma configuração de câmera traseira de 64.0 + 12.0 + 5.0 + 5.0 MP. Por

questões práticas, as folhas afetadas foram removidas e registradas, conforme mostrado na Figura 20d.

As imagens foram pré-processadas antes da fase de treinamento para padronização das amostras. Foi criado um código utilizando *Python* e a biblioteca *OpenCV* para realizar este processo. O código recebe as imagens brutas, aplica uma região de interesse (ROI) para um efeito de zoom e redimensiona as imagens para o formato padrão de 640 x 640 pixels. A biblioteca *Rembg* (Gatis, 2021), uma ferramenta projetada para remoção automática de planos de fundo, foi então utilizada para a remoção. A Figura 20e mostra as amostras após a fase de pré-processamento. O conjunto de dados pré-processado está disponível online sob o registro DOI: [10.5281/zenodo.13272038](https://doi.org/10.5281/zenodo.13272038).

Todas as 6.282 lesões identificadas nas 1.645 imagens de folhas capturadas em campo foram anotadas manualmente usando a ferramenta da API do *Roboflow*, seguindo as especificações do conjunto de dados COCO. As amostras anotadas foram então divididas aleatoriamente em conjuntos de treinamento, validação e teste, conforme detalhado na Tabela 6.

Figura 20 – (a) Fluxo geral da pesquisa; (b) Plantação de onde as amostras foram coletadas; (c) Folha afetada pela cercosporiose; (d) Exemplos de coletas de amostras; (e) Amostras após pré-processamento.




Tabela 6 – Aspectos gerais do conjunto de dados.

Divisão do Conjunto de Dados	Número de Amostras	de Lesões Anotadas
Treinamento	1040	3943
Validação	294	1131
Teste	309	1208
Total	1645	6282

3.2 Modelos e Treinamento

Quatro modelos YOLOv8-Seg pré-treinados foram testados: YOLOv8n-Seg (nano), YOLOv8s-Seg (small), YOLOv8m-Seg (medium) e YOLOv8l-Seg (large). Esses modelos diferem em sua velocidade de resposta, capacidade de segmentação e precisão.

Além disso, foram utilizados quatro modelos Mask R-CNN. São eles: `mask_rcnn_R101_3x` e `mask_rcnn_R50_3x`. O modelo `mask_rcnn_R101_3x` utiliza um backbone ResNet-101 com 101 camadas, enquanto o modelo `mask_rcnn_R50_3x` usa um backbone ResNet-50 com 50 camadas. Ambos os modelos incorporam um FPN para aprimorar a extração de características em múltiplas escalas. Finalmente, os modelos `mask_rcnn_R101_C4_3x` e `mask_rcnn_R50_C4_3x` foram testados. Esses modelos também utilizam ResNet-101 e ResNet-50 como backbones, mas diferem dos modelos baseados em FPN, pois utilizam o bloco C4 (Convolutional Cascade for Object Detection).

Os modelos pré-treinados foram utilizados como ponto de partida para o treinamento com o conjunto de dados personalizado. YoloV8 e Mask-RCNN adotam procedimentos de treinamento distintos: o YoloV8 utiliza épocas, enquanto o Detectron2 baseia-se no número de iterações. As 300 épocas recomendadas pela *Ultralytics* foram seguidas como referência. O número correspondente de iterações para o Mask-RCNN foi então calculado com base no tamanho do conjunto de dados de treinamento (1.040) e um tamanho de lote - *batch size* de 16, resultando em 19.500 iterações. A taxa de aprendizado foi ajustada para 0.001. Todos os modelos foram treinados e testados usando o ambiente *Google Colab*, equipado com uma GPU NVIDIA Tesla T4, com suporte para CUDA versão 12.2 e até 15 GB de RAM.

A qualidade do treinamento foi avaliada através da métrica mAP₅₀ aplicada na tarefa de segmentação sobre o conjunto de dados de validação. O mAP₅₀ calcula a média dos valores de precisão média para todas as classes, onde a precisão é avaliada em um IoU de 0.5. O mAP₅₀ pode ser expresso matematicamente da seguinte forma:

$$\text{mAP}_{50} = \frac{1}{N} \sum_{i=1}^N \text{AP}_{50}(i) \quad (1)$$

Onde N é o número total de classes, e $\text{AP}_{50}(i)$ representa a precisão média para a classe i em um limiar de IoU de 0.5. A Precisão Média ($\text{AP}_{50}(i)$) para uma classe específica é

calculada como a área sob a curva precisão-recall dessa classe, dada por:

$$AP_{50}(i) = \int_0^1 p_{50}(r) dr \quad (2)$$

Onde $p_{50}(r)$ denota a precisão no nível de recall r para $IoU = 0.5$.

3.3 Threshold de Confiança de Inferência (CT)

O limiar de confiança - *Confidence Threshold* (CT) é um parâmetro crucial para filtrar as detecções de objetos e os resultados de segmentação nos frameworks YOLOv8 e Mask R-CNN (Reddy *et al.*, 2024). Ele desempenha um papel fundamental na determinação da validade das segmentações ou máscaras previstas. Ambos os modelos atribuem pontuações de confiança a cada pixel ou segmento previsto, indicando a probabilidade de ele pertencer a uma classe específica. Por exemplo, uma pontuação de confiança de 0.9 indica 90% de certeza de que a segmentação está correta. O CT pode ser ajustado durante a inferência para influenciar os resultados, permitindo o ajuste fino do desempenho do modelo. Neste estudo, todas as métricas avaliadas foram analisadas variando o CT de 0.1 a 0.9 em incrementos de 0.1.

3.4 Determinação da Severidade

A severidade de uma doença em uma planta pode ser considerada como a proporção da unidade da planta que apresenta sintomas visíveis da doença, geralmente expressa como uma porcentagem, de acordo com a equação (Madden, 2007):

$$S = \frac{\text{Área do tecido foliar doente}}{\text{Área total da folha}} \times 100\% \quad (3)$$


Um algoritmo foi desenvolvido para determinar as áreas de referência das lesões. Ele acessa as anotações previamente criadas no formato *COCO* utilizando a API disponibilizada pela *Roboflow*. O algoritmo gera uma máscara binária normalizada onde os pixels brancos (valor = 1) representam a lesão e os pixels pretos (valor = 0) indicam ausência de lesão. O algoritmo então conta o número de pixels brancos para revelar a área danificada. De maneira similar, o código acessa as máscaras previstas pelos modelos e cria máscaras binárias para as áreas de lesão previstas.

Para calcular a área total da folha, a imagem pré-processada passa por um algoritmo de detecção de contornos utilizando métodos como *Otsu Thresholding* e *Dilate*. O processo começa com a conversão da imagem pré-processada para escala de cinza e a aplicação do método de *thresholding* de Otsu. Em seguida, uma operação de dilatação é aplicada para acentuar os contornos, seguida pela identificação desses contornos na imagem processada. Finalmente, a área total em pixels dentro do contorno é determinada.

3.5 Classificação do Nível de Severidade

Escalas diagramáticas foram utilizadas como referência para a divisão dos níveis de severidade da doença. Dada a ausência de escalas específicas para a mancha foliar de *Cercospora* em *Capsicum frutescens* (pimenta) na literatura, foi utilizada a escala de severidade desenvolvida por (Michereff *et al.*, 2006) para *Capsicum annuum* (pimentão) (Figura 21). Essa escolha foi justificada pelo fato de que a mancha foliar de *Cercospora* afeta ambas as plantas e elas pertencem à mesma família, *Solanaceae*. Com base na escala de Michereff, a severidade foi categorizada em sete classes distintas, conforme mostrado na Tabela 7.

Figura 21 – Escala diagramática para avaliação da mancha foliar de *Cercospora* em pimentão (*Capsicum annuum*), indicando níveis de severidade de 1.5%, 3.5%, 8.0%, 16.5%, 31.0% e 50.0%.



Fonte: Adaptado de (Michereff *et al.*, 2006).

Tabela 7 – Escala de níveis de severidade baseada em porcentagem de severidade.

Severidade (%)	Nível
Saudável	0
0-1.5	I
1.5-3.5	II
3.5-8.0	III
8.0-16	IV
16.3-31	V
≥ 50	VI

3.6 Métricas de Avaliação

Nesta fase, os modelos treinados customizados foram avaliados utilizando imagens do conjunto de teste que não foram vistas pelo modelo durante o treinamento. A avaliação

envolveu a aplicação de métricas tanto no nível de pixel quanto na classificação final dos níveis de severidade.

3.6.1 Métricas de Avaliação no Nível de Pixel

As máscaras de referência das lesões e as previstas foram comparadas utilizando métricas de avaliação pixel a pixel para determinar a acurácia, precisão, revocação (*recall*) e F1-score, considerando os pixels Verdadeiro Positivo (TP), Verdadeiro Negativo (TN), Falso Positivo (FP) e Falso Negativo (FN).

TP refere-se a um pixel corretamente identificado como parte da lesão nas máscaras predita e de referência. TN denota um pixel reconhecido corretamente como não parte da lesão em ambas as máscaras. FP descreve um pixel incorretamente identificado como parte da lesão na máscara predita quando não é parte da lesão na máscara de referência. FN indica um pixel erroneamente identificado como não parte da lesão na máscara predita, enquanto é parte da lesão na máscara de referência.

De acordo com Sokolova e Lapalme (2009), a *Acurácia* (Eq. 4) é uma métrica de desempenho comumente utilizada que mede a correção geral do modelo nas predições. É a razão entre o número de amostras corretamente previstas e o número total de amostras no conjunto de dados. A *Precisão* (Eq. 5) é uma medida que indica a proporção de predições positivas corretas dentre as predições positivas totais feitas pelo modelo. É calculada dividindo o número de TPs pela soma de TPs e FPs. A *Revocação* (Eq. 6), ou sensibilidade, é a proporção de lesões verdadeiramente detectadas pelo modelo em relação ao número total de lesões existentes. O *F1-score* (Eq. 7) é uma medida que combina precisão e revocação em uma única métrica para fornecer uma visão equilibrada do desempenho do modelo. É a média harmônica entre precisão e revocação.

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (4)$$

$$\text{Precisão} = \frac{TP}{TP + FP} \times 100\% \quad (5)$$

$$\text{Revocação} = \frac{TP}{TP + FN} \times 100\% \quad (6)$$

$$F1\text{-score} = \frac{2 \times \text{Precisão} \times \text{Revocação}}{\text{Precisão} + \text{Revocação}} \times 100\% \quad (7)$$

Além das métricas, os tempos médios de inferência de todos os modelos no conjunto de teste foram registrados.

A métrica de Média da União de Interseção - Mean Intersection over Union (MIoU) (Eq. 8) foi utilizada para avaliar a qualidade da segmentação dos modelos. Essa métrica avalia o desempenho considerando as áreas de sobreposição e união entre as máscaras de valor real e as máscaras previstas.

$$MIoU = \frac{1}{N} \sum_{i=1}^N \frac{TP_i}{TP_i + FP_i + FN_i} = \frac{1}{N} \sum_{i=1}^N \frac{\text{Área de sobreposição}_i}{\text{Área de união}_i} \quad (8)$$


3.6.2 Métricas de Avaliação do Nível de Severidade

Os valores de severidade observados e previstos foram avaliados utilizando regressão linear, o coeficiente de determinação (R^2) e o Erro Quadrático Médio (RMSE) - Eq. 9. Um gráfico de KDE (Estimativa de Densidade por Kernel) foi criado para analisar os resíduos, e um boxplot foi utilizado para avaliar os desvios por nível de severidade. Em seguida, os níveis de severidade observados e previstos de todos os modelos foram comparados utilizando matrizes de confusão. Por fim, foram calculados a acurácia, precisão, recall e F1-score para a classificação do nível de severidade.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (9)$$

O diagrama na Figura 22 ilustra o procedimento detalhado da metodologia.

Figura 22 – Diagrama dos passos da metodologia.



4 Resultados

Os valores de mAP50 dos modelos (Tabela 8) obtidos no conjunto de validação demonstraram o sucesso do treinamento e dos hiperparâmetros definidos, variando de um valor mínimo de 0,893 para o modelo mask_rcnn_R50_FPN_3x até um valor máximo de 0,925 para o modelo YOLOv8n-Seg. Esses valores indicam a robustez dos modelos, que seguiram para a avaliação das métricas no conjunto de teste, como será discutido nas seções seguintes.

Tabela 8 – Resultados de mAP no conjunto de validação.


Modelo	mAP50
mask_rcnn_R101_FPN_3x	0,894
mask_rcnn_R50_FPN_3x	0,893
mask_rcnn_R101_C4_3x	0,901
mask_rcnn_R50_C4_3x	0,897
YOLOv8n-Seg	0,925
YOLOv8s-Seg	0,915
YOLOv8m-Seg	0,909
YOLOv8l-Seg	0,906

4.1 Avaliação em Nível de Pixel

Os resultados indicam que alguns modelos tiveram dificuldade em segmentar com precisão as lesões em baixos valores de CT, frequentemente classificando erroneamente grandes porções da superfície da folha como lesões. A Figura 23 apresenta dois exemplos de máscaras binárias preditas em diferentes níveis de CT.


Para garantir uma avaliação precisa em nível de pixel e evitar distorções nos resultados, os dados dos níveis de CT onde ocorreram erros significativos foram excluídos. Como resultado, alguns gráficos subsequentes podem apresentar descontinuidades nos níveis mais baixos de CT.

Figura 23 – **(a)** Da esquerda para a direita: exemplo de imagem RGB de folha pré-processada; máscara binária predita de lesão com o modelo mask_rcnn_R101_3x com $CT=0,6$; máscara binária predita de lesão com o modelo mask_rcnn_R101_3x com $CT=0,1$. **(b)** Da esquerda para a direita: exemplo de imagem RGB de folha pré-processada; máscara binária predita de lesão com o modelo YOLOv8s-Seg em $CT=0,8$; máscara binária predita de lesão com o modelo YOLOv8s-Seg em $CT=0,2$.




Os gráficos nas Figuras 24a e 24b exibem a distribuição das médias de FPs e FNs no conjunto de teste em diferentes níveis de CT, variando de 0,1 a 0,9.

(a) Média de Falsos Positivos vs. Limite de Confiança.



(b) Média de Falsos Negativos vs. Limite de Confiança.



Os dados revelam uma tendência esperada para todos os modelos: à medida que o CT aumenta, os FPs tendem a diminuir, enquanto os FNs aumentam. Com o aumento do CT, os modelos tornam-se mais seletivos. Isso significa que as detecções feitas com menor confiança, frequentemente associadas aos FPs, são descartadas, reduzindo sua ocorrência. No entanto, essa seletividade aumentada faz com que os modelos sejam mais propensos a rejeitar detecções verdadeiras, aumentando os FNs.

Os gráficos também indicam que os modelos baseados em Mask R-CNN tendem a apresentar valores mais baixos de FPs e FNs em comparação aos modelos baseados no YOLOv8, com a diferença mais significativa observada nos FPs. As seções subsequentes explorarão o impacto desse comportamento em outros resultados. Além disso, os gráficos destacam um desequilíbrio mais acentuado nos modelos baseados no YOLOv8 em níveis de CT mais elevados.

Esses achados estão refletidos no cálculo das métricas em nível de pixel. A Tabela 9 apresenta as médias gerais dessas métricas, o valor ou intervalo de CT para os melhores resultados e o tempo médio de inferência de cada modelo no conjunto de dados de teste.

Os resultados de MIoU indicam que a sobreposição entre as máscaras de referência e as

Tabela 9 – Avaliação das métricas em nível de pixel.

Modelo	MIoU	Acurácia	Precisão	Recall	F1-Score	CT	Tempo Inf. (ms)
mask_rcnn_R101_FPN_3x	0.860	0.999	0.942	0.907	0.924	0.3	119
mask_rcnn_R50_FPN_3x	0.848	0.999	0.957	0.881	0.918	(0.6 - 0.7)	89
mask_rcnn_R101_C4_3x	0.838	0.999	0.956	0.870	0.911	0.8	473
mask_rcnn_R50_C4_3x	0.840	0.999	0.942	0.883	0.911	0.9	477
YOLOv8n-Seg	0.807	0.998	0.911	0.853	0.881	0.6	27
YOLOv8s-Seg	0.808	0.998	0.905	0.882	0.893	(0.4-0.5)	34
YOLOv8m-Seg	0.805	0.998	0.906	0.876	0.891	(0.1-0.4)	41
YOLOv8l-Seg	0.805	0.998	0.906	0.878	0.892	(0.2-0.4)	62

máscaras preditas ultrapassou 80% para todos os modelos. Todos os modelos baseados em Mask R-CNN alcançaram valores mais altos do que os modelos YOLOv8, com o modelo mask_rcnn_R101_FPN_3x se destacando ao alcançar o maior valor de MIoU entre os modelos testados, com 86%.

É crucial observar que a acurácia de pixel não é uma métrica comparativa adequada neste contexto. Devido à natureza das imagens, o número de TNs para imagens binarizadas supera significativamente o número de TPs, levando a um desequilíbrio e resultando em valores artificialmente elevados de acurácia (99,9% para os modelos baseados em Mask R-CNN e 99,8% para os modelos baseados em YOLOv8).

As métricas de precisão, recall e F1-Score também demonstram que os modelos baseados em Mask R-CNN geralmente alcançam melhores resultados em métricas de nível de pixel. Todos os modelos Mask R-CNN alcançaram valores mais altos de F1-Score. Por outro lado, os tempos médios de inferência dos modelos baseados em YOLOv8 foram significativamente menores. O modelo mask_rcnn_R50_C4_3x apresentou o maior tempo médio de inferência, de 477 ms, enquanto o modelo YOLOv8n-Seg apresentou o menor, de 27 ms.

4.2 Avaliação do Nível de Severidade

O cálculo automático da severidade de referência no conjunto de dados de teste com 309 amostras identificou 46 amostras saudáveis, 133 amostras de nível I, 105 amostras de nível II e 25 amostras de nível III. Isso significa que, entre as amostras coletadas no campo, a maior severidade observada não ultrapassou 8% da área da folha afetada pela doença.

A Tabela 10 apresenta os melhores valores de RMSE (comparando as severidades de referência e previstas), juntamente com os respectivos valores de CT.


O modelo mask_rcnn_R101_FPN_3x obteve o melhor resultado com RMSE de 0.132. Entre os modelos baseados em YOLOv8, o YOLOv8s-Seg obteve o melhor resultado com RMSE de 0.136. Na análise do comportamento do RMSE com a variação de CT, os melhores valores de RMSE foram obtidos com CTs mais baixos. Para entender melhor esse resultado, foi analisada a soma de todas as áreas de lesão preditas e de referência para cada CT. Como ilustrado na Figura 25, observou-se que a diferença entre as áreas

Tabela 10 – Resultados de RMSE.

Modelo	RMSE	CT
mask_rcnn_R101_FPN_3x	0.132	0.3
mask_rcnn_R50_FPN_3x	0.184	0.3
mask_rcnn_R101_C4_3x	0.186	0.1
mask_rcnn_R50_C4_3x	0.159	0.1
YOLOv8n-Seg	0.153	0.6
YOLOv8s-Seg	0.136	0.3
YOLOv8m-Seg	0.150	0.1
YOLOv8l-Seg	0.149	0.2

preditas e as de referência (linha tracejada) aumentou conforme o CT aumentava. Com CTs mais baixos, as áreas preditas estavam mais alinhadas com as áreas de referência.

Figura 25 – Área total de lesão predita e de referência para cada avaliação de modelo.



CTs mais baixos permitem uma detecção mais abrangente, incluindo uma gama mais ampla de previsões. Em contraste, CTs mais altos são mais restritivos e levam a menos detecções, como observado na análise de FPs e FNs. Além disso, as áreas preditas pelos modelos baseados em Mask R-CNN são menores do que aquelas preditas pelos modelos baseados em YOLOv8. Isso indica que, embora os modelos Mask R-CNN alcancem maior precisão em nível de pixel ao minimizar os FPs, sua abordagem conservadora resulta em áreas preditas menores.

Após realizar inferências utilizando os oito modelos no conjunto de dados de teste e classificar os níveis de severidade, as classificações de níveis de severidade preditas foram comparadas com as de referência usando matrizes de confusão. A partir dessas matrizes, foram calculadas a precisão, o recall e o F1-score para a classificação de severidade. A Tabela 11 mostra os resultados.

Tabela 11 – Resultados das métricas de classificação de severidade.

Modelo	Precisão	Recall	F1-Score	CT
mask_rcnn_R101_FPN_3x	0.949	0.948	0.947	0.6
mask_rcnn_R50_FPN_3x	0.928	0.926	0.924	(0.3-0.4)
mask_rcnn_R101_C4_3x	0.931	0.929	0.928	(0.1-0.2)
mask_rcnn_R50_C4_3x	0.930	0.929	0.928	(0.1)
YOLOv8n-Seg	0.952	0.951	0.951	(0.6-0.7)
YOLOv8s-Seg	0.949	0.948	0.948	(0.3-0.4)
YOLOv8m-Seg	0.946	0.945	0.948	(0.1-0.4)
YOLOv8l-Seg	0.949	0.948	0.948	(0.1)


As métricas de classificação para todos os modelos superaram 90%. Dentre eles, o modelo YOLOv8n-Seg obteve a maior precisão de classificação com 95,2%. O modelo baseado em Mask R-CNN com o melhor desempenho foi o mask_rcnn_R101_FPN_3x, com 94,9%. De modo geral, os modelos baseados em YOLOv8 superaram os modelos baseados em Mask R-CNN na classificação. Apesar de ter um RMSE melhor, o modelo mask_rcnn_R101_FPN_3x obteve um desempenho ligeiramente inferior ao do YOLOv8n-Seg em precisão de classificação. Essa discrepância ocorre porque as classificações de nível de severidade são feitas em intervalos pré-definidos e não refletem necessariamente os erros contínuos representados pelo RMSE.

A análise a seguir focará mais nos resultados de classificação dos melhores modelos de cada framework: mask_rcnn_R101_FPN_3x e YOLOv8n-Seg.


A Figura 26a apresenta as matrizes de confusão com os melhores desempenhos em classificação de severidade para cada modelo.

Figura 26 – Matrizes de confusão para classificação de severidade pelos melhores modelos de cada framework.


(a) Matriz de confusão para o modelo mask_rcnn_R101_FPN_3x.




(b) Matriz de confusão para o modelo YOLOv8n-Seg.



(c) Matriz de confusão percentual para o modelo mask_rcnn_R101_FPN_3x.




(d) Matriz de confusão percentual para o modelo YOLOv8n-Seg.



Ambos os modelos identificaram corretamente todas as folhas saudáveis (Nível 0), alcançando 100% de precisão nesta categoria. No entanto, o modelo mask_rcnn_R101_FPN_3x tende a subestimar a severidade. À medida que a severidade aumenta, os erros de classificação se tornam mais pronunciados: 8% das folhas de Nível II foram classificadas incorretamente como Nível I, e 24% das folhas de Nível III foram classificadas incorretamente como Nível II. De maneira similar, o modelo YOLOv8n-Seg também subestima os Níveis II e III, mas com uma menor variação de 8% em ambos os casos. Essa diferença reflete-se na precisão por nível, onde o desempenho do Mask R-CNN caiu para 72,3% para o nível de severidade III, enquanto o YOLO alcançou 91,4%. A Figura 27 mostra as regressões lineares de ambos os modelos entre as severidades previstas e de referência.

Figura 27 – Regressão linear para classificação de severidade pelos melhores modelos de cada framework.

- (a) Regressão linear para mask_rcnn_R101_FPN_3x. para (b) Regressão linear para o modelo YOLOv8n-Seg.



Conforme indicado pelos valores de RMSE mencionados anteriormente, os coeficientes de determinação também destacam um melhor ajuste dos dados pelo modelo mask_rcnn_R101_FPN_3x em comparação com o modelo YOLOv8n-Seg, com valores de R^2 de 0,991 e 0,986, respectivamente. No entanto, o desvio da linha de regressão em relação à linha de identidade confirma uma maior tendência de subestimação pelo modelo mask_rcnn_R101_FPN_3x. Essa tendência é ilustrada ainda mais pelo gráfico de Estimativa de Densidade de Kernel (KDE) para os resíduos (preditos - observados) de ambos os modelos na Figura 28.

Figura 28 – Gráfico de Estimativa de Densidade do Núcleo (KDE).






Figura 29 – Boxplot dos resíduos para classificação de severidade pelos melhores modelos de cada framework.

(a) Boxplot para mask_rcnn_R101_FPN_3x.



(b) Boxplot para o modelo YOLOv8n-Seg.



Ambos os modelos exibem curvas assimétricas à esquerda com predominância de resíduos negativos. No entanto, o modelo mask_rcnn_R101_FPN_3x apresenta uma assimetria mais pronunciada e um pico mais alto, indicando um número maior de resíduos negativos.

Para avaliar o comportamento dos resíduos por nível de severidade, foram criados gráficos de boxplot para cada modelo nos níveis I, II e III. Esses gráficos comparam a distribuição dos resíduos entre os valores de severidade de referência e os valores previstos para os três níveis diferentes de severidade, representando folhas doentes.

No boxplot para o modelo mask_rcnn_FPN_3x (Figura 29a), no nível de severidade I, a maioria dos resíduos está centrada em torno de zero, com uma distribuição relativamente simétrica. No nível de severidade II, a distribuição dos resíduos é mais estreita, centrada em torno de zero, com poucos valores discrepantes e uma leve tendência para subestimação. No Nível III, a distribuição é mais ampla e deslocada para valores negativos, indicando

uma tendência de subestimação das severidades mais altas, com maior variabilidade.

Para o modelo YOLOv8n-Seg, no nível de severidade I, a maioria dos resíduos também está centrada em torno de zero, mas com menos valores discrepantes e um intervalo interquartilico um pouco mais estreito, sugerindo menor variabilidade. No nível de severidade II, a distribuição dos resíduos é comparável à do modelo `mask_rcnn_R101_FPN_3x`, centrada em torno de zero, com poucos valores discrepantes e um intervalo interquartilico ligeiramente mais amplo, indicando uma variabilidade um pouco maior. No nível de severidade III, a distribuição dos resíduos mostra uma tendência para subestimação, mas com menor variabilidade e uma quantidade moderada de valores discrepantes, com alguns resíduos se estendendo para valores mais negativos.

Em conclusão, ambos os gráficos indicam que os modelos tendem a subestimar severidades mais altas, mas o modelo YOLOv8n-Seg demonstra maior consistência e menor variabilidade nas previsões do que o modelo `mask_rcnn_R101_FPN_3x`. Isso sugere que o modelo YOLOv8 apresenta um desempenho ligeiramente melhor em termos de precisão e consistência na previsão dos níveis de severidade.

5 Discussão

Este estudo demonstrou que os modelos baseados em Mask R-CNN e YOLOv8 são eficazes na identificação automática de lesões e na classificação dos níveis de severidade da cercosporiose em folhas de pimenta. A principal diferença entre os frameworks está no processo de inferência: o YOLOv8 realiza a tarefa em um único estágio, enquanto o Mask R-CNN utiliza dois estágios, o que impacta diretamente os resultados.

No nível de pixel, os modelos Mask R-CNN apresentaram uma ligeira vantagem, com melhor sobreposição de máscaras (MIoU), menores médias de falsos positivos e falsos negativos e menor variação nas métricas de precisão e recall em diferentes limiares de confiança (CT). No entanto, os intervalos ótimos de CT para essa avaliação não coincidem com os ótimos para métricas como RMSE e a comparação entre áreas previstas e áreas de referência, pois estas dependem mais do equilíbrio entre erros de predição e da qualidade das máscaras geradas. Além disso, a comparação direta do RMSE com a classificação de severidade é limitada, já que o RMSE trabalha com valores contínuos, enquanto a classificação se baseia em intervalos discretos.

Em termos de classificação de severidade, o estilo conservador do Mask R-CNN, que prioriza a precisão em detrimento do recall, tende a prever áreas de lesão menores. Em folhas com alta severidade, isso resulta em uma acumulação de erros, levando à subestimação dos níveis de severidade. Essa subestimação torna-se especialmente problemática quando os valores previstos se aproximam dos limites dos intervalos de classificação (Níveis 0, I, II e III).

Por outro lado, os modelos YOLOv8 exibiram uma maior variabilidade nos erros,

prevendo tanto áreas maiores quanto menores do que as de referência, o que proporcionou um equilíbrio melhor nas previsões para folhas com alta severidade.

Dentre os modelos avaliados, o `mask_rcnn_R101_FPN_3x` com CT de 0,6 e o `YOLOv8n-Seg` com CT entre 0,6 e 0,7 foram os melhores para a classificação de níveis de severidade, sendo o `YOLOv8n-Seg` o que apresentou resultados superiores. Mesmo com uma maior variação de erro associada ao CT, o `YOLOv8n-Seg` demonstrou que a redução da precisão no nível de pixel, compensada por velocidades de inferência mais rápidas, não prejudicou a eficácia na classificação, desde que o CT seja otimizado.

Além disso, os tempos de inferência dos modelos `YOLOv8` foram significativamente menores; por exemplo, o tempo médio de inferência do `mask_rcnn_R101_FPN_3x` foi 4,4 vezes maior que o do `YOLOv8n-Seg`.

Em resumo, embora a abordagem em dois estágios do Mask R-CNN forneça uma segmentação mais precisa no nível de pixel, o framework de um estágio do `YOLOv8`, especialmente o `YOLOv8n-Seg`, mostrou-se mais eficaz para a classificação dos níveis de severidade e mais rápido na inferência. Esses resultados ressaltam a importância de selecionar o framework adequado e ajustar corretamente o limiar de confiança (CT) conforme os requisitos específicos de cada aplicação.

6 Conclusão

Nos últimos anos, a pesquisa na agricultura tem aproveitado cada vez mais as tecnologias de aprendizado profundo para melhorar as práticas modernas, aumentar a qualidade das culturas, automatizar processos e promover a sustentabilidade. Este estudo realizou um experimento abrangente para avaliar e comparar o desempenho de duas arquiteturas recentes e amplamente utilizados de aprendizado profundo —`YOLOv8` e `Mask R-CNN`— na segmentação e no cálculo automático da severidade de doenças em plantas. O foco específico do estudo foi a cercosporiose em folhas de pimenta. Com base nos resultados, as seguintes conclusões-chave foram extraídas:

1. Os modelos `Mask R-CNN` se destacaram nas métricas de nível de pixel, com o modelo `mask_rcnn_R101_FPN_3x` atingindo um MIoU de 86% e um F1-score de 92,4%. O melhor modelo `YOLOv8`, `YOLOv8s-Seg`, obteve um MIoU de 80,8% e um F1-score de 89,3%.
2. Na classificação de níveis de severidade, os modelos `YOLOv8` superaram, com o `YOLOv8n-Seg` alcançando o maior F1-score de 95,1%. Em comparação, o melhor modelo `Mask R-CNN` atingiu um F1-score de 94,7% nesta tarefa.
3. Apesar das métricas superiores a nível de pixel, os modelos `Mask R-CNN` mostraram uma tendência a subestimar a severidade. Isso resultou em áreas previstas geralmente

menores que as de referência, levando a erros mais significativos na classificação de níveis de severidade mais altos.

4. O limiar de confiança (CT) se mostrou um fator crítico no desempenho. O YOLOv8n-Seg, embora sensível às mudanças no CT, entregou os melhores resultados de classificação de severidade em seu limiar ótimo.
5. Os modelos YOLOv8 demonstraram tempos de inferência significativamente mais rápidos do que os modelos Mask R-CNN, com o modelo YOLOv8 mais rápido processando em 27 ms e o melhor modelo Mask R-CNN em 89 ms.
6. Este estudo ressalta a importância de selecionar cuidadosamente as métricas de avaliação com base na aplicação específica. A escolha das métricas pode impactar significativamente o desempenho percebido dos modelos, destacando que a aplicação final deve guiar os critérios de avaliação.

7 Trabalhos Futuros

Pesquisas futuras podem se concentrar no ajuste fino dos hiperparâmetros do processo de treinamento para explorar possíveis melhorias no desempenho do modelo. A otimização de parâmetros poderia gerar previsões mais precisas e aprimorar a eficácia geral dos modelos.

Além disso, estudos futuros poderiam testar o conjunto de dados utilizando os modelos recentemente lançados YOLOv9 e YOLOv10. Ao avaliar esses modelos mais novos, os pesquisadores podem analisar a precisão no nível de pixel e a precisão na classificação com base nos níveis de severidade. Comparações como essas serão valiosas para entender os avanços nas tecnologias de detecção e segmentação de objetos e sua aplicabilidade a tarefas específicas, como a avaliação da severidade da cercosporiose em folhas de pimenta.

8 Anexo

Aqui serão apresentados alguns códigos e trechos de algoritmos mais relevantes elaborados pelo autor e que foram citados ao longo do texto.

8.1 Pré-Processamento das Imagens

```
1 import cv2
2 import matplotlib.pyplot as plt
3 from rembg import remove
4 import glob
5 import os
6 import numpy as np
```

```

7 from PIL import Image
8 import matplotlib.image as mpimg
9
10 # Funcao para aplicar ROI e zoom em imagens
11 def aplicar_roi_zoom(input_folder, output_folder, roi_width, roi_height)
    :
12     # Percorre todas as imagens na pasta de entrada
13     for filename in os.listdir(input_folder):
14         if filename.endswith(".jpg") or filename.endswith(".png"):
15             img = cv2.imread(os.path.join(input_folder, filename))
16             img_height, img_width = img.shape[:2]
17             center_x, center_y = img_width // 2, img_height // 2
18             roi_left = center_x - roi_width // 2
19             roi_right = center_x + roi_width // 2
20             roi_top = center_y - roi_height // 2
21             roi_bottom = center_y + roi_height // 2
22             roi_img = img[roi_top:roi_bottom, roi_left:roi_right]
23             cv2.imwrite(os.path.join(output_folder, filename), roi_img)
24
25 # Funcao para remover o fundo de imagens
26 def seg_backremoval(pasta_origem, pasta_destino='/content/
    fotos_backremove'):
27     arquivos = glob.glob(f'{pasta_origem}/*')
28     for arquivo in arquivos:
29         img = Image.open(arquivo)
30         output = remove(img)
31         try:
32             orientation = img._getexif()[274]
33         except:
34             orientation = 1
35         if orientation == 6:
36             output = output.rotate(-90, expand=True)
37         if not os.path.exists(pasta_destino):
38             os.makedirs(pasta_destino)
39         nome_arquivo = os.path.splitext(os.path.basename(arquivo))[0]
40         caminho_saida = f"{pasta_destino}/{nome_arquivo}_backremoved.png
            "
41         output.save(caminho_saida)
42
43 # Funcao para mostrar imagens
44 def mostrar_imagens(input_folder):
45     for filename in os.listdir(input_folder):
46         if filename.endswith(".jpg") or filename.endswith(".png"):
47             img = mpimg.imread(os.path.join(input_folder, filename))
48             plt.imshow(img)
49             plt.title(filename)
50             plt.show()

```

```

51
52 # Funcao para apagar arquivos de uma pasta
53 def apagar_arquivos(caminho_pasta):
54     for nome_arquivo in os.listdir(caminho_pasta):
55         caminho_arquivo = os.path.join(caminho_pasta, nome_arquivo)
56         os.remove(caminho_arquivo)
57
58 # Funcao para modificar o fundo de imagens e salva-las como JPEG
59 def modificar_fundo(pasta_origem, pasta_destino='/content/
    fotos_backremove_jpg'):
60     arquivos = glob.glob(f'{pasta_origem}/*')
61     for arquivo in arquivos:
62         imagem = Image.open(arquivo)
63         nova_imagem = Image.new("RGB", imagem.size, (255, 255, 255))
64         nova_imagem.paste(imagem, (0, 0), imagem)
65         nome_arquivo = os.path.splitext(os.path.basename(arquivo))[0]
66         nova_imagem.save(f'{pasta_destino}/{nome_arquivo}.jpg')

```

8.2 Inferência e geração das máscaras previstas com o modelo treinado - Mask R-CNN

```

1 import os
2 import cv2
3 import numpy as np
4
5
6 caminho_val = test_set_path
7 caminho_mascaras = '/content/mascaras_previstas' # Caminho para salvar
    as mascaras
8
9 os.makedirs(caminho_mascaras, exist_ok=True)
10
11 # Loop atraves de cada arquivo na pasta
12 for filename in os.listdir(caminho_val):
13
14     if filename.endswith('.jpg') or filename.endswith('.png'):
15         # Leia a imagem usando o OpenCV
16         img = cv2.imread(os.path.join(caminho_val, filename))
17
18         # Realize a inferencia na imagem
19         outputs = predictor(img)
20
21         # Obtenha as previsoes de saida
22         predictions = outputs["instances"].to("cpu")
23
24         # Obtenha as mascarar de segmentacao de instancias
25         masks = predictions.pred_masks

```

```

26
27     # Combine as mascaras em uma unica mascara binaria
28     combined_mask = masks.sum(dim=0).numpy()
29     binary_mask = (combined_mask > 0).astype(np.uint8) * 255
30
31     # Crie o caminho para salvar a mascara
32     mascara_path = os.path.join(caminho_mascaras, filename)
33
34     # Salve a mascara binaria como imagem
35     cv2.imwrite(mascara_path, binary_mask)

```

8.3 Inferência e geração das máscaras previstas com o modelo treinado - YOLOv8

```

1  import cv2
2  import numpy as np
3  import os
4
5
6  image_folder = '/content/lesoesv1-44/test/images'
7  model_path = '/content/V44_100Epochs-Augmentation.pt'
8  output_folder = '/content/mascaras-previstas'
9
10
11  os.makedirs(output_folder, exist_ok=True)
12
13  # Carregue o modelo
14  model = YOLO(model_path)
15
16  # Loop pelos arquivos de imagem na pasta de entrada
17  for image_filename in os.listdir(image_folder):
18      image_path = os.path.join(image_folder, image_filename)
19
20      # Carregue a imagem
21      img = cv2.imread(image_path)
22
23      # previsao
24      results = model.predict(img)
25
26      # matriz de zeros com a mesma forma da imagem em escala de cinza
27      combined_mask = np.zeros_like(cv2.cvtColor(img, cv2.COLOR_BGR2GRAY),
28                                   dtype=np.float32)
29
30      for result in results:
31          for mask in result.masks.data:
32              # Converta a mascara para um array NumPy e some com a
33              # mascara combinada

```

```

32         mask = mask.cpu().numpy()
33         combined_mask += mask
34
35     # Normalize a matriz combinada para valores entre 0 e 255
36     combined_mask /= len(results)
37     combined_mask = (combined_mask * 255).astype(np.uint8)
38
39     # Salvar mascara combinada com o mesmo nome do arquivo de imagem na
        pasta de saida
40     output_mask_filename = os.path.join(output_folder, os.path.splitext(
        image_filename)[0] + '.jpg')
41     cv2.imwrite(output_mask_filename, combined_mask)
42
43 print("Mascaras previstas foram salvas na pasta 'mascaras_previstas'.")

```

8.4 Detecção de contornos e cálculo da área da folha

```

1  import os
2  import cv2
3  import numpy as np
4  from google.colab.patches import cv2_imshow
5
6  # Caminho para a pasta de teste contendo as imagens
7  test_set_path = '/content/lesoesv1-35/test'
8
9  area_folha_lista = []
10
11 # Loop atraves de cada arquivo na pasta de teste
12 for filename in os.listdir(test_set_path):
13
14     if filename.endswith('.jpg') or filename.endswith('.png'):
15         # Carregar a imagem da folha
16         img = cv2.imread(os.path.join(test_set_path, filename))
17         img_gray = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY)
18
19         # Aplique um limiar usando o metodo de Otsu
20         _, thresh = cv2.threshold(img_gray, 0, 255, cv2.THRESH_BINARY +
            cv2.THRESH_OTSU)
21
22         # Aplicar dilatacao
23         kernel = cv2.getStructuringElement(cv2.MORPH_RECT, (5, 5))
24         dilated = cv2.erode(thresh, kernel, iterations=1)
25
26         # Encontre os contornos na imagem dilatada
27         contours, _ = cv2.findContours(dilated, cv2.RETR_LIST, cv2.
            CHAIN_APPROX_SIMPLE)

```

```

28
29     # Ordene os contornos por area em ordem decrescente
30     contours = sorted(contours, key=cv2.contourArea, reverse=True)
31
32     # Verifique se existem pelo menos dois contornos
33     if len(contours) >= 2:
34         # Obtenha o segundo maior contorno
35         second_largest_contour = contours[1]
36
37         # Calcule a area do segundo maior contorno
38         area_folha = cv2.contourArea(second_largest_contour)
39         area_folha_lista.append(area_folha)
40
41         print(f'A area de {filename} e de {area_folha}')
42
43     else:
44         print(f'Nao foi possivel encontrar o segundo maior contorno
45             de {filename}')

```

8.5 Cálculo de Área de Lesão - Imagens de Referência

```

1 import cv2
2 import numpy as np
3 import os
4
5 # Caminho para a pasta contendo as imagens
6 folder_path = '/content/mascaras_annotadas/'
7
8 # Lista para armazenar os calculos de area de lesao
9 area_lesao_referencia_lista = []
10
11 # Percorrer todas as imagens na pasta
12 for filename in os.listdir(folder_path):
13     if filename.endswith('.jpg'):
14         # Construir o caminho completo para a imagem
15         image_path = os.path.join(folder_path, filename)
16
17         # Carregar a imagem em escala de cinza
18         image = cv2.imread(image_path, cv2.IMREAD_GRAYSCALE)
19
20         # Normalizar os valores dos pixels para o intervalo [0, 1]
21         normalized_image = image.astype(np.float32) / 255.0
22
23         # Aplicar uma limiarizacao para transformar a imagem normalizada
24         # em binaria

```

```

24     _, binary_image = cv2.threshold(normalized_image, 0.5, 1.0, cv2.
    THRESH_BINARY)
25
26     # Calcular o numero de pixels brancos na imagem binaria
    normalizada
27     white_pixel_count = np.sum(binary_image == 1)
28
29     # Adicionar o resultado a lista
30     area_lesao_referencia_lista.append(white_pixel_count)
31
32     print(f'Area Lesao Referencia: {filename}:{white_pixel_count}')

```

8.6 Cálculo de Área de Lesão - Imagens Previstas

```

1  import cv2
2  import numpy as np
3  import os
4
5  # Caminho para a pasta contendo as imagens
6  folder_path = '/content/mascaras_previstas'
7
8  # Lista para armazenar os calculos de area de lesao
9  area_lesao_prevista_lista = []
10
11 # Percorrer todas as imagens na pasta
12 for filename in os.listdir(folder_path):
13     if filename.endswith('.jpg'):
14         # Construir o caminho completo para a imagem
15         image_path = os.path.join(folder_path, filename)
16
17         # Carregar a imagem em escala de cinza
18         image = cv2.imread(image_path, cv2.IMREAD_GRAYSCALE)
19
20         # Normalizar os valores dos pixels para o intervalo [0, 1]
21         normalized_image = image.astype(np.float32) / 255.0
22
23         # Aplicar uma limiarizacao para transformar a imagem normalizada
    em binaria
24         _, binary_image = cv2.threshold(normalized_image, 0.5, 1.0, cv2.
    THRESH_BINARY)
25
26         # Calcular o numero de pixels brancos na imagem binaria
    normalizada
27         white_pixel_count = np.sum(binary_image == 1)
28
29         # Adicionar o resultado a lista

```

```

30         area_lesao_prevista_lista.append(white_pixel_count)
31
32     print(f'Area Lesao Prevista: {filename}:{white_pixel_count}')

```

8.7 Determinação da severidade de referência e prevista

```

1  severidade_referencia_lista = []
2  severidade_prevista_lista = []
3
4  for i in range(0, len(area_lesao_prevista_lista)):
5      severidade_referencia = (area_lesao_referencia_lista[i] /
6                               area_folha_lista[i]) * 100
7      severidade_prevista = (area_lesao_prevista_lista[i] /
8                             area_folha_lista[i]) * 100
9
10     severidade_referencia = round(severidade_referencia, 2)
11     severidade_prevista = round(severidade_prevista, 2)
12
13     severidade_referencia_lista.append(severidade_referencia)
14     severidade_prevista_lista.append(severidade_prevista)

```

Referências

AMORIM, Lilian *et al.* Manual de fitopatologia, 2016.

BARBURICEANU, Stefania *et al.* Convolutional neural networks for texture feature extraction. Applications to leaf disease classification in precision agriculture. **IEEE Access**, IEEE, v. 9, p. 160085–160103, 2021.

BOCK *et al.* From visual estimates to fully automated sensor-based measurements of plant disease severity: status and challenges for improving accuracy. **Phytopathology Research**, v. 2, p. 1–30, 2020. Disponível em: <https://api.semanticscholar.org/CorpusID:218654085>.

BOGUSZ, Stanislaw *et al.* Brazilian Capsicum peppers: capsaicinoid content and anti-oxidant activity. **Journal of the science of food and agriculture**, v. 98 1, p. 217–224, 2018. Disponível em: <https://api.semanticscholar.org/CorpusID:27722938>.

BOLYA, Daniel *et al.* Yolact: Real-time instance segmentation. *In: PROCEEDINGS of the IEEE/CVF international conference on computer vision. [S. l.: s. n.]*, 2019. p. 9157–9166.

BRUCAL, Stanley Glenn E. *et al.* Development of Tomato Leaf Disease Detection using YoloV8 Model via RoboFlow 2.0. **2023 IEEE 12th Global Conference on Consumer Electronics (GCCE)**, p. 692–694, 2023. Disponível em: <https://api.semanticscholar.org/CorpusID:265258133>.

CHARISIS, Christos; ARGYROPOULOS, Dimitrios. Deep learning-based instance segmentation architectures in agriculture: A review of the scopes and challenges. **Smart Agricultural Technology**, 2024. Disponível em: <https://api.semanticscholar.org/CorpusID:269144172>.

DAMINDA THUSHARA ANDRAHANNADI, and others. Development of a web based system to practice the estimation of plant disease severity. *In*: disponível em: <https://api.semanticscholar.org/CorpusID:219110491>.

DONG, Mac Trinh Cong *et al.* Rice Leaf Diseases Detection Using YOLOv8. **JST: Engineering and Technology for Sustainable Development**, 2024. Disponível em: <https://api.semanticscholar.org/CorpusID:269885843>.

FAYE, Demba *et al.* Plant Disease Severity Assessment Based on Machine Learning and Deep Learning: A Survey. **Journal of Computer and Communications**, 2023. Disponível em: <https://api.semanticscholar.org/CorpusID:263016509>.

GARY STOREY, and others. Leaf Disease Segmentation and Detection in Apple Orchards for Precise Smart Spraying in Sustainable Agriculture. **Sustainability**, 2022. Disponível em: <https://api.semanticscholar.org/CorpusID:246404683>.

GATIS. **REMBG**. [*S. l.: s. n.*], 2021. Disponível em: <https://github.com/danielgatis/rembg>. Acesso em: 24 de maio de 2023.

GENG *et al.* Survey of recent progress in semantic image segmentation with CNNs. **Science China Information Sciences**, Springer, v. 61, p. 1–18, 2018.

GENTILHOMME, Theophile *et al.* Towards smart pruning: ViNet, a deep-learning approach for grapevine structure estimation. **Computers and Electronics in Agriculture**, Elsevier, v. 207, p. 107736, 2023.

GOLD, Kaitlin M. Plant Disease Sensing: Studying Plant-Pathogen Interactions at Scale. **mSystems**, v. 6, 2021. Disponível em: <https://api.semanticscholar.org/CorpusID:244132368>.

GOMES, Gisely Paula *et al.* Characterization of biochemical compounds and antioxidant activity of “dedo-de-moça” chili pepper accessions. **Horticultura Brasileira**, 2019. Disponível em: <https://api.semanticscholar.org/CorpusID:211559880>.

HAFIZ, Abdul Mueed; BHAT, Ghulam Mohiuddin. A survey on instance segmentation: state of the art. **International Journal of Multimedia Information Retrieval**, v. 9, p. 171–189, 2020. Disponível em: <https://api.semanticscholar.org/CorpusID:220280409>.

JOCHER *et al.* **Ultralytics YOLO**. [*S. l.: s. n.*], 2023. Software disponível sob licença AGPL-3.0. Disponível em: <https://github.com/ultralytics/ultralytics>.

KOK, and others. Obscured tree branches segmentation and 3D reconstruction using deep learning and geometrical constraints. **Computers and electronics in agriculture**, Elsevier, v. 210, p. 107884, 2023.

KUMAR, Deepak; KUKREJA, Vinay. Early recognition of wheat powdery mildew disease based on mask RCNN. *In: IEEE. 2022 International Conference on Data Analytics for Business and Industry (ICDABI)*. [*S. l.: s. n.*], 2022. p. 542–546.

MADDEN, and others. **The study of plant disease epidemics**. St. Paul, MN: APS Press, 2007.

MICHEREFF, Sami Jorge *et al.* Elaboração e validação de escala diagramática para a cercosporiose do pimentão. **Summa phytopathologica**, SciELO Brasil, v. 32, p. 260–266, 2006.

QADRI, Syed Asif Ahmad *et al.* Plant Disease Detection and Segmentation using End-to-End YOLOv8: A Comprehensive Approach. **2023 IEEE 13th International Conference on Control System, Computing and Engineering (ICCSCE)**, p. 155–160, 2023. Disponível em: <https://api.semanticscholar.org/CorpusID:261565392>.

RANGEL, Lorena I *et al.* Cercospora beticola: The intoxicating lifestyle of the leaf spot pathogen of sugar beet. **Molecular Plant Pathology**, v. 21, p. 1020–1041, 2020. Disponível em: <https://api.semanticscholar.org/CorpusID:220630485>.

RANI, A.; ARROYO, D.O.; DURDEVIC, P. **Defect Detection in Synthetic Fibre Ropes using Detectron2 Framework**. [*S. l.: s. n.*], 2023. arXiv: 2309.01469. Disponível em: <https://arxiv.org/abs/2309.01469>.

REDDY, S.S. *et al.* You only look once model-based object identification in computer vision. **IAES International Journal of Artificial Intelligence (IJ-AI)**, 2024. Disponível em: <https://api.semanticscholar.org/CorpusID:266591642>.

SAPKOTA, and others. Comparing YOLOv8 and Mask RCNN for object segmentation in complex orchard environments. **ArXiv**, abs/2312.07935, 2023. Disponível em: <https://api.semanticscholar.org/CorpusID:266191181>.

SCHINDELIN, Johannes *et al.* Fiji: an open-source platform for biological-image analysis. **Nature Methods**, v. 9, n. 7, p. 676–682, jul. 2012. ISSN 1548-7105. DOI: 10.1038/nmeth.2019. Disponível em: <https://doi.org/10.1038/nmeth.2019>.

SCHNEIDER *et al.* NIH Image to ImageJ: 25 years of image analysis. **Nature Methods**, v. 9, n. 7, p. 671–675, jul. 2012. ISSN 1548-7105. DOI: 10.1038/nmeth.2089. Disponível em: <https://doi.org/10.1038/nmeth.2089>.

SHARMA, Jatin *et al.* Wheat Powdery Mildew Automatic Identification Through YOLOv8 Instance Segmentation. **2024 11th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO)**, p. 1–5, 2024. Disponível em: <https://api.semanticscholar.org/CorpusID:269775774>.

SHARMA, Rabi *et al.* A Survey on Object Instance Segmentation. **SN Computer Science**, v. 3, p. 1–23, 2022. Disponível em: <https://api.semanticscholar.org/CorpusID:252600582>.

SINGH, Arti *et al.* Machine learning for high-throughput stress phenotyping in plants. **Trends in plant science**, Elsevier, v. 21, n. 2, p. 110–124, 2016.

SOKOLOVA, Marina; LAPALME, Guy. A systematic analysis of performance measures for classification tasks. **Information processing & management**, Elsevier, v. 45, n. 4, p. 427–437, 2009.

SUNANDA, and others. Disease Feature Extraction and Disease Detection from Paddy Crops Using Image Processing and Deep Learning Technique. *In*: disponível em: <https://api.semanticscholar.org/CorpusID:213935494>.

TODA, Yosuke; OKURA, Fumio. How convolutional neural networks diagnose plant disease. **Plant Phenomics**, AAAS, 2019.

TRECHA, and others. Entraves do cultivo convencional e as potencialidades do cultivo orgânico do pimentão no Brasil. **Revista Thema**, v. 14, p. 291–302, 2017. Disponível em: <https://api.semanticscholar.org/CorpusID:193957379>.

UDAWANT, Prashant; SRINATH, Pravin. Cotton Leaf Disease Detection Using Instance Segmentation. **J. Cases Inf. Technol.**, v. 24, p. 1–10, 2022. Disponível em: <https://api.semanticscholar.org/CorpusID:248768991>.

VALICHARLA, Sruthi Keerthi. Weed Recognition in Agriculture: A Mask R-CNN Approach. *In*: disponível em: <https://api.semanticscholar.org/CorpusID:235251059>.

WANG, Nan *et al.* Segmentation and phenotype calculation of rapeseed pods based on YOLO v8 and mask R-convolution neural networks. **Plants**, MDPI, v. 12, n. 18, p. 3328, 2023.

WANG, Xiangheng *et al.* A comprehensive survey on object detection YOLO. *In: INTERNATIONAL Symposium on Advanced Technologies and Applications in the Internet of Things*. [S. l.: s. n.], 2023. Disponível em: <https://api.semanticscholar.org/CorpusID:261125293>.

WEILAND, John J.; KOCH, Georg. Sugarbeet leaf spot disease (*Cercospora beticola* Sacc.)dagger. **Molecular plant pathology**, v. 5 3, p. 157–66, 2004. Disponível em: <https://api.semanticscholar.org/CorpusID:205242384>.

WILSON, Calum Rae. Plant pathogens – the great thieves of vegetable value. *In: disponível em: https://api.semanticscholar.org/CorpusID:111993986*.

WU, Y. *et al.* **Detectron2**. [S. l.: s. n.], 2019. <https://github.com/facebookresearch/detectron2>.

CAPÍTULO III

FITOVIEW: INTEGRAÇÃO DE REDES NEURAIS CONVOLUCIONAIS E DADOS CLIMÁTICOS NO MANEJO DA CERCOSPORIOSE EM PIMENTA MALAGUETA³

RESUMO

As doenças em plantas representam grandes limitações à produtividade agrícola, frequentemente resultando em perdas significativas de rendimento e uso indiscriminado de defensivos. Este estudo apresenta o FitoView, um sistema de apoio à decisão através de aplicativo móvel baseado em nuvem que integra aprendizado profundo com previsão meteorológica em tempo real para o manejo sustentável de doenças de plantas. Demonstrado através de um estudo de caso sobre mancha-de-cercóspora em pimenta malagueta, o sistema emprega modelos YOLOv8 customizados para detecção automática de doenças, classificação e quantificação de severidade em nível de pixel, combinados com dados meteorológicos da API OpenMeteo. A inovação central reside em uma matriz de decisão integrada que considera três dimensões: severidade da doença avaliada por IA, previsões de risco climático de 48 horas e condições ideais de pulverização, gerando quatro cenários de manejo contextualizados com períodos de reavaliação personalizados. A validação dos dados da API OpenMeteo em quatro cidades de Sergipe demonstrou boa correlação, com coeficientes de Pearson (r) de 0,90-0,97 para temperatura, 0,81-0,95 para umidade e 0,92-0,95 para radiação solar, correspondendo a valores de R^2 de 0,65-0,94. O modelo de detecção de objetos YOLOv8 alcançou precisão 100% e recall médio macro de 89% em todas as classes de doenças, com a detecção de mancha-de-cercóspora alcançando métricas perfeitas (100% de precisão, recall e F1-score). O mAP50 (mean Average Precision at IoU 0,5) — métrica que avalia a precisão média das detecções considerando sobreposição mínima de 50% entre a caixa delimitadora predita e a de referência — foi utilizado para monitorar a convergência do treinamento. A validação em campo comprovou a eficácia do sistema ao identificar a mancha-de-cercóspora e estimar sua severidade. Ao integrar esses dados ao risco climático, a ferramenta gerou recomendações, como tratamentos

alternativos e reavaliações de curto prazo. A arquitetura de Aplicação Web Progressiva, implantada em nuvem, garante acessibilidade sem requisitos de instalação, enquanto o design modular permite escalabilidade para culturas e doenças adicionais, representando um avanço local na democratização de ferramentas de agricultura de precisão baseadas em IA para pequenos agricultores no Brasil.

Palavras-chave: Agricultura de Precisão; Fitopatologia; Visão Computacional; YOLOv8; Previsão Meteorológica; Manejo Integrado de Doenças

FITOVIEW: INTEGRATION OF CONVOLUTIONAL NEURAL NETWORKS AND CLIMATE DATA IN CERCOSPORA LEAF SPOT MANAGEMENT IN MALAGUETA PEPPER

ABSTRACT

Plant diseases represent major limitations to agricultural productivity, frequently resulting in significant yield losses. This study presents FitoView, a cloud-based mobile decision support system that integrates deep learning with real-time weather forecasting for sustainable plant disease management. Demonstrated through a case study on cercospora leaf spot in malagueta pepper, the system employs custom YOLOv8 models for automatic disease detection, classification, and pixel-level severity quantification, combined with meteorological data from the OpenMeteo API. The central innovation lies in an integrated decision matrix that considers three dimensions: AI-assessed disease severity, 48-hour climate risk forecasts, and ideal spraying conditions, generating four contextualized management scenarios with personalized reassessment periods. Validation of OpenMeteo API data in four cities in Sergipe demonstrated good correlation, with Pearson coefficients (r) of 0.90-0.97 for temperature, 0.81-0.95 for humidity, and 0.92-0.95 for solar radiation, corresponding to R^2 values of 0.65-0.94. The YOLOv8 object detection model achieved perfect precision (100%) and macro-average recall of 89% across all disease classes, with cercospora leaf spot detection achieving perfect metrics (100% precision, recall, and F1-score). The mAP50 (mean Average Precision at IoU 0.5) — a metric that evaluates the average precision of detections considering a minimum overlap of 50% between the predicted and reference bounding boxes — was used to monitor training convergence. Field validation in Lagarto, Sergipe, confirmed the practical use of the system: it accurately detected cercospora leaf spot, estimated severity, and, combined with climate risk, generated recommendations for alternative treatment and short-term reassessment. The Progressive Web Application architecture, deployed on Google Cloud Platform, ensures accessibility without installation requirements, while the modular design allows scalability for additional crops and diseases, representing a significant advance in the democratization of AI-based precision agriculture tools for small farmers in Brazil.

Keywords: Precision Agriculture; Plant Pathology; Computer Vision; YOLOv8; Weather Forecasting; Integrated Disease Management

1 Introdução

As doenças em plantas estão entre os fatores mais significativos que limitam a produtividade agrícola global, com perdas de rendimento estimadas variando de 20% a 40% nas principais culturas (Savary *et al.*, 2019). Tais perdas não apenas ameaçam a segurança alimentar, mas também impõem impactos econômicos e sociais substanciais aos pequenos agricultores, que frequentemente carecem de acesso a tecnologias avançadas de manejo. Tradicionalmente, o manejo de doenças em plantas tem se baseado fortemente no controle químico, particularmente fungicidas. Embora esses insumos possam ser eficazes, também estão associados à contaminação ambiental, impactos negativos na biodiversidade e riscos à saúde humana (Popp *et al.*, 2013). A necessidade de estratégias de manejo mais sustentáveis e precisas tornou-se cada vez mais urgente. De forma complementar, as condições climáticas são um fator central no desenvolvimento e disseminação de doenças de plantas. Temperatura, umidade relativa e precipitação governam a sobrevivência de patógenos, taxas de infecção e dinâmica de epidemias (Fenu; Mallocci, 2021; Agrios, 2005).

O manejo de doenças baseado em previsão tem sido estudado há décadas, com modelos que relacionam variáveis meteorológicas ao risco de infecção servindo como ferramentas-chave em programas de manejo integrado de pragas e doenças. Nos últimos anos, a acessibilidade de dados meteorológicos expandiu-se substancialmente por meio de Interfaces de Programação de Aplicações (APIs), permitindo monitoramento climático em tempo real e preditivo. No Brasil, essas tecnologias podem ser particularmente úteis, pois muitas localidades carecem de estações meteorológicas físicas, que são escassamente distribuídas ou frequentemente inativas. Segundo de Aguiar *et al.* (2020), o Instituto Nacional de Meteorologia (INMET), a rede oficial de dados climáticos no Brasil, opera 245 estações convencionais e 464 automáticas. No entanto, esse número ainda é insuficiente para cobrir adequadamente os 8,4 milhões de km² do país, especialmente nas regiões interioranas e do norte.

Concomitantemente, os avanços em Inteligência Artificial (IA) abriram novas perspectivas para a proteção de culturas. As Redes Neurais Convolucionais (CNNs) alcançaram precisão notável na detecção, classificação e estimativa de severidade de doenças baseadas em imagens em uma ampla gama de culturas e patossistemas (Ferentinos, 2018; Kamilaris *et al.*, 2018; Leite; Brito; Faccioli, 2024; Shi *et al.*, 2023). Exemplos incluem aplicações bem-sucedidas para requeima tardia do tomate, brusone do arroz e sarna da maçã (Mohanty *et al.*, 2016; Liu; Wang, 2021). Os métodos tradicionais de avaliação visual, ainda amplamente utilizados em muitos contextos, apresentam desvantagens importantes: são subjetivos, altamente dependentes da expertise do avaliador, demorados e propensos a inconsistências quando repetidos entre avaliadores ou ao longo do tempo. Além disso, as escalas visuais frequentemente carecem de precisão na quantificação de níveis intermediários de severidade, o que pode comprometer a precisão de estudos epidemiológicos e

decisões de manejo (Nutter Jr *et al.*, 1993; Bock *et al.*, 2010).

Vários estudos investigaram tanto a classificação de doenças de plantas baseada em imagens, estimativa de severidade e previsão de doenças baseada em clima. CNNs e outras abordagens de aprendizado profundo foram aplicadas ao controle de doenças de plantas em míldio da videira, ferrugem do trigo e sarna da maçã (Barbedo, 2019; Too *et al.*, 2019), enquanto modelos baseados em clima foram usados para prever epidemias de requeima tardia da batata e ferrugem foliar do trigo (Hijmans, 2000; Del Ponte, a. o., 2005). No entanto, essas abordagens são frequentemente desenvolvidas de forma independente, com esforços limitados para integrar diagnóstico baseado em imagens e previsão de risco climático em ferramentas unificadas orientadas ao agricultor. Além disso, a maioria das soluções permanece restrita a contextos de pesquisa, carecendo de escalabilidade e acessibilidade para a agricultura de pequeno porte. Essas lacunas destacam a novidade do presente trabalho, que combina detecção de doenças e quantificação de severidade baseadas em CNN com previsões meteorológicas em tempo real em uma aplicação móvel baseada em nuvem. É importante destacar que, até onde se tem conhecimento, essa abordagem integrada é inédita ou ao menos inovadora em nível mundial.

Esta pesquisa busca preencher essa lacuna apresentando o FitoView, um sistema de apoio à decisão móvel que integra análise de imagens baseada em CNN com dados de previsão meteorológica. Embora projetado como uma solução modular e escalável para diferentes culturas e doenças, sua viabilidade é demonstrada através de um estudo de caso sobre pimenta malagueta (*Capsicum* spp.), com foco na mancha-de-cercóspora.

2 Estudo de caso: Mancha-de-cercóspora em pimenta malagueta

As espécies de pimenta e pimenta malagueta do gênero *Capsicum* têm sido consumidas há mais de 7.000 anos no México e permanecem como uma cultura importante em todo o mundo (Kraft *et al.*, 2014). No Brasil, o mercado de pimenta possui importância econômica e cultural significativa, fornecendo as indústrias alimentícia, farmacêutica e cosmética (Carvalho *et al.*, 2006). Entre as variedades cultivadas, pimenta malagueta, dedo-de-moça, cambuci, cumari-do-Pará, de-cheiro, murupi, de-bode e biquinho são as mais proeminentes, consumidas frescas (*in natura*), em molhos, conservadas ou desidratadas (Alencar, 2017). O cultivo ocorre em quase todas as regiões do país, com Goiás, Minas Gerais, São Paulo e Sergipe se destacando como principais produtores.

Um centro de produção notável é o Perímetro Irrigado Piauí em Lagarto, Sergipe, estabelecido em 1987. Caracterizado por pequenas propriedades com menos de 5 hectares, este projeto envolve 421 propriedades e beneficia mais de 3.500 pessoas (CODERSE (Companhia de Desenvolvimento Regional de Sergipe), 2023). A pimenta malagueta (*Capsicum frutescens*) é uma variedade importante, com 120 toneladas produzidas em 2021. Apesar desse potencial, a adoção de tecnologia permanece limitada, e a pressão de

doenças impõe limitação à produtividade. Entre essas, a mancha-de-cercóspora, causada por *Cercospora capsici*, é uma das mais problemáticas.

A doença é comum em regiões quentes e úmidas e pode reduzir severamente a área foliar fotossintética, levando à malformação de frutos e perdas de rendimento (Del Ponte, E., 2007). Estudos relatam que o patógeno se desenvolve de forma ótima a 20–25°C sob umidade relativa superior a 90% (Kawagoe, 1998; Pinto; Teixeira, 2022).

Os sintomas aparecem principalmente nas folhas como lesões circulares com centros marrom-claros e margens escuras, que podem aumentar, causar desfolha prematura ou formar perfurações (Lim *et al.*, 2003; Carmo *et al.*, 2006; Ribeiro *et al.*, 2008). Nenhuma variedade de pimenta resistente está atualmente disponível (Lim *et al.*, 2003), tornando o manejo desafiador. Medidas preventivas incluem rotação de culturas, fertilização balanceada e uso de sementes saudáveis (Lopes *et al.*, 2003), enquanto o controle frequentemente depende de fungicidas considerados perigosos ao meio ambiente (AGROFIT, 2010). Práticas alternativas, como a aplicação de calda bordalesa, têm sido exploradas como opções mais sustentáveis (Pinto; Teixeira; Ribeiro, 2022).

3 Materiais e Métodos

3.1 Aquisição de Dados Climáticos

Os dados meteorológicos necessários para a aplicação foram obtidos usando a API OpenMeteo. OpenMeteo é um serviço meteorológico de código aberto que fornece dados de previsão e histórico meteorológico de alta resolução agregando informações de modelos de previsão numérica do tempo (NWP), incluindo os da Administração Oceânica e Atmosférica Nacional (NOAA - *National Oceanic and Atmospheric Administration*) e do Centro Europeu de Previsões Meteorológicas de Médio Prazo (ECMWF). O serviço é reconhecido por sua acessibilidade e transparência, fornecendo solicitações de API gratuitas para projetos não comerciais, o que o torna uma fonte confiável para desenvolvimento científico (Zippenfenig, 2023).

Para este estudo, as variáveis climáticas-chave consideradas foram previsões horárias de temperatura do ar (°C) e umidade relativa (%), destacadas na literatura como principais fatores do desenvolvimento da mancha-de-cercóspora e da dinâmica de epidemias (Agrios, 2005; Fenu; Mallocci, 2021). Essas variáveis foram recuperadas programaticamente para coordenadas geográficas específicas e são utilizadas diretamente na avaliação do risco climático para a doença. Adicionalmente, o sistema também recupera previsões horárias de radiação solar global (R_s , em MJ m^{-2}) e evapotranspiração de referência (ET_0) diretamente da API OpenMeteo. A radiação solar é uma variável relevante para sistemas de apoio à decisão agrícola, pois influencia o desenvolvimento vegetal e a fisiologia das plantas (Allen *et al.*, 1998). A aplicação disponibiliza valores de ET_0 aos usuários (produtores e responsáveis técnicos) como ferramenta auxiliar para determinação da lâmina d'água e

otimização do manejo da irrigação. A validação da radiação solar foi incluída na análise comparativa com dados do INMET para verificar a qualidade desta variável, considerando que muitas estações meteorológicas convencionais no Brasil não medem esta variável ou apresentam lacunas significativas de dados (Monteiro; Martins, 2019).

3.2 Validação de Dados da API OpenMeteo

Para validar os dados de clima para a região-alvo, foi realizada uma comparação com medições de referência. Dada a ausência de uma estação INMET na cidade-alvo — Lagarto/SE, esta validação utilizou dados de quatro outros municípios escolhidos para representar as principais zonas climáticas de Sergipe: Aracaju (costeira), Nossa Senhora da Glória (sertão semiárido), Brejo Grande (costeira/delta) e Itabaianinha (agreste/zona de transição). Esta abordagem multi-local é crítica para confirmar a aplicabilidade da API em toda a região agrícola, uma vez que Sergipe apresenta zonas climáticas diversas.

Para cada localização, séries temporais horárias de temperatura do ar, radiação solar e umidade relativa da API OpenMeteo para o ano de 2024 foram estatisticamente comparadas com os registros correspondentes das estações meteorológicas automáticas do INMET. A comparação empregou o erro médio absoluto (MAE), raiz do erro quadrático médio (RMSE), o coeficiente de correlação de Pearson (r) e o coeficiente de determinação (R^2), conforme definido nas Equações 1, 2, 3 e 4:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - x_i| \quad (1)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2} \quad (2)$$

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (3)$$

$$R^2 = r^2 \quad (4)$$

Onde: n é o número total de observações horárias; x_i representa o valor de referência da estação INMET; y_i representa o valor previsto pela API OpenMeteo; e $\bar{x}$ e $\bar{y}$ são as médias dos valores observados e previstos, respectivamente.

3.3 Desenvolvimento de Modelos CNN Customizados

3.3.1 Detecção e Classificação de Doenças

Para a detecção e classificação de doenças, foi desenvolvido e treinado um modelo YOLOv8 customizado para realizar detecção de objetos e classificação de doenças em folhas de pimenta malagueta. O modelo adota a arquitetura padrão de detecção de objetos

YOLOv8, permitindo a identificação e categorização de regiões foliares doentes dentro de caixas delimitadoras. A implementação foi realizada usando o framework Ultralytics YOLOv8 (versão 8.2.103) em Python 3.12.11, com PyTorch 2.8.0+cu126, e executado em uma GPU Tesla T4 (15 GB de memória) no ambiente Google Colab.

Para a montagem do conjunto de dados, a principal contribuição veio do Conjunto de Dados de Doenças Foliares de Pimenta de Bangladesh (Nirob *et al.*, 2025), suplementado com amostras adicionais extraídas de estudos sobre classificação de doenças de plantas empregando abordagens de aprendizado com poucos exemplos (Uzhinskiy, 2025; Uzhinskiy *et al.*, 2021). Para o caso específico de detecção de mancha-de-cercóspora, uma coleção dedicada de imagens de folhas de pimenta malagueta anotadas para esta doença serviu como conjunto de dados principal (Leite, 2024).

A organização e anotação do conjunto de dados foram facilitadas usando Roboflow (<https://roboflow.com>), uma plataforma de visão computacional que agiliza o fluxo de trabalho de anotação e garante padrões consistentes de rotulagem. O conjunto de dados original foi inicialmente dividido em treinamento (60%), validação (20%) e teste (20%), compreendendo 149, 49 e 49 imagens, respectivamente. Após procedimentos de aumento de dados, a divisão de treinamento expandiu para 447 imagens, mantendo os conjuntos de validação e teste originais para avaliação imparcial do modelo. O conjunto de dados abrange cinco classes distintas de doenças: mancha-de-cercóspora, deficiência nutricional, edema, folhas saudáveis e mancha bacteriana.

A distribuição de instâncias anotadas (anotações de objetos) entre classes e divisões do conjunto de dados é apresentada na Tabela 12. Esta distribuição estratificada garante representação equilibrada de todas as classes de doenças nos conjuntos de treinamento, validação e teste, o que é crucial para desempenho robusto do modelo e métricas de avaliação confiáveis.

Tabela 12 – Distribuição de instâncias anotadas (anotações de objetos) por classe entre as divisões do conjunto de dados.

Classe	Anotações Treino	Anotações Validação	Anotações Teste
Mancha-de-cercóspora	111	12	9
Deficiência nutricional	201	9	14
Edema	69	9	3
Saudável	81	13	9
Mancha bacteriana	114	11	18

O treinamento foi conduzido ao longo de 50 épocas usando o otimizador AdamW com uma taxa de aprendizado inicial de 0,001 e momentum de 0,9. O modelo empregou precisão mista automática (AMP) para treinamento e utilizou técnicas de aumento de dados incluindo aumento de mosaico, inversão horizontal aleatória (probabilidade 0,5) e várias transformações de espaço de cores (ajustes HSV: matiz $\pm 1,5\%$, saturação $\pm 70\%$, valor $\pm 40\%$). Aumentações adicionais incluíram translação aleatória ($\pm 10\%$), escalona-

mento ($\pm 50\%$) e transformações de perspectiva para melhorar a robustez e capacidade de generalização do modelo.

O processo de treinamento utilizou um tamanho de lote de 16 com um tamanho de imagem de entrada de 640×640 pixels. Parada antecipada foi configurada com uma paciência de 100 épocas para prevenir sobreajuste. A função de perda combinou três componentes: perda de regressão de caixa (peso: 7,5), perda de classificação (peso: 0,5) e perda focal de distribuição para regressão de caixa delimitadora (peso: 1,5).

3.3.2 Avaliação de Severidade de Doenças

O componente de avaliação de severidade do sistema FitoView utiliza um modelo YOLOv8-Seg customizado especificamente desenvolvido e validado para segmentação em nível de pixel e quantificação de severidade de mancha-de-cercóspora em folhas de pimenta malagueta sob condições naturais de campo. Diferentemente do modelo de detecção descrito acima, que realiza detecção de objetos com caixas delimitadoras, o modelo de avaliação de severidade emprega segmentação em nível de pixel para delinear precisamente os limites das lesões e calcular a severidade da doença como uma porcentagem da área foliar afetada.

Este modelo, em conjunto com o algoritmo de detecção de severidade, foi previamente desenvolvido e avaliado de forma abrangente pelos autores em um estudo que comparou oito arquiteturas de aprendizado profundo (quatro variantes YOLOv8 e quatro modelos Mask R-CNN) usando um conjunto de dados de 1.645 imagens de folhas de pimenta malagueta com 6.282 lesões anotadas (Leite; Brito; Faccioli *et al.*, 2025). No estudo, o modelo YOLOv8-Seg selecionado demonstrou desempenho superior na classificação de severidade, alcançando 91,4% de acurácia para níveis altos de severidade (nível III) em comparação com 72,3% para Mask R-CNN, mantendo eficiência computacional com tempos de inferência de 27ms por imagem.

3.4 Fluxo de Trabalho do Sistema e Lógica de Decisão para Mancha-de-Cercóspora em Pimenta Malagueta

O algoritmo central da aplicação integra as entradas fornecidas pelo usuário com a análise de risco climático e a classificação da doença e de sua severidade. Essa integração é organizada em uma matriz de decisão que considera três dimensões principais: a severidade detectada, o risco climático previsto para as próximas 48 horas e as condições ideais para pulverização. Essa abordagem combinada possibilita recomendações de manejo mais precisas e ajustadas ao contexto real do produtor. O fluxo completo — desde a configuração inicial até a emissão da recomendação — para o caso específico da mancha-de-cercóspora é detalhado nas etapas a seguir.

3.4.1 Etapa 1: Configuração do Usuário e Seleção de Doença

O fluxo de trabalho do usuário começa ao acessar a URL pública da aplicação. Na tela inicial, o usuário configura a análise selecionando a cultura de interesse (atualmente suportando apenas a pimenta malagueta) e definindo a localização, seja escolhendo uma cidade predefinida ou fornecendo coordenadas específicas de latitude e longitude. Após a configuração, o usuário é apresentado a uma interface de seleção de doenças que oferece dois caminhos: seleção manual de uma lista curada de doenças específicas da cultura selecionada, ou detecção de doenças orientada por IA. O caminho de seleção manual exibe doenças com imagens ilustrativas e texto descritivo, enquanto o caminho de detecção por IA utiliza o modelo de detecção de objetos YOLOv8 para identificar automaticamente doenças a partir de imagens de folhas capturadas pelo usuário. Se a detecção por IA falhar ou nenhuma doença for identificada, o sistema retorna à interface de seleção manual. Uma vez que uma doença é selecionada ou detectada, o sistema apresenta o painel principal com informações agrometeorológicas abrangentes. Incluindo dados climáticos atuais (temperatura, umidade relativa, velocidade do vento e condições gerais), uma previsão de risco climático de 48 horas baseada nas condições ótimas de desenvolvimento da doença-alvo—*Cercospora capsici* neste estudo de caso—, e, como recurso adicional, a evapotranspiração de referência (ET_0) do dia anterior com atualizações horárias em tempo real, disponibilizada para uso opcional por produtores e responsáveis técnicos na determinação da lâmina d'água e no planejamento do manejo da irrigação. O painel também fornece informações educacionais sobre a doença, incluindo sintomas, medidas preventivas de controle e referências científicas.

3.4.2 Etapa 2: Avaliação Inicial e Decisão do Usuário

O painel então apresenta um ponto de decisão, perguntando ao usuário—via um botão deslizante simples "sim/não"—se sintomas visíveis da doença estão presentes no campo. Esta resposta determina o caminho subsequente, orientando o sistema em direção a recomendações de manejo preventivo, monitoramento ou corretivo - convencional ou alternativo.

3.4.3 Etapa 3a: Manejo Preventivo/Monitoramento (Sem Sintomas Visíveis)

Se o usuário selecionar "não", a aplicação muda para monitoramento preventivo baseado em risco climático. Neste modo, o sistema analisa a previsão do tempo para as próximas 48 horas e classifica, por hora, o risco de desenvolvimento de *Cercospora capsici* de acordo com temperatura (T) e umidade relativa (UR). O risco foi dividido em quatro categorias para abranger todos os cenários possíveis:

- *Risco Baixo*: $T < 20^{\circ}\text{C}$ ou $UR < 80\%$.
- *Risco Moderado*: $20^{\circ}\text{C} \leq T \leq 25^{\circ}\text{C}$ e $80\% \leq UR < 90\%$.

- *Risco Elevado*: ($20^{\circ}\text{C} \leq T \leq 25^{\circ}\text{C}$ e $\text{UR} \geq 90\%$) ou ($T > 25^{\circ}\text{C}$ e $80\% \leq \text{UR} < 90\%$).
- *Risco Alto*: $T > 25^{\circ}\text{C}$ e $\text{UR} \geq 90\%$.

Dado que o sistema calcula o risco climático para as 48 horas seguintes à requisição, resultando em uma série temporal de valores de risco que podem variar significativamente ao longo do período, foi necessário desenvolver um método para determinar o risco predominante utilizado na matriz de decisão. O sistema adota uma abordagem que combina a representatividade temporal (risco com maior percentual de ocorrência) com o princípio da precaução amplamente adotado em fitopatologia, reconhecendo que períodos relativamente curtos de condições favoráveis durante o dia podem ser críticos para o desenvolvimento de epidemias, e que em manejo de doenças é preferível atuar com prevenção.

O algoritmo de determinação do risco predominante funciona da seguinte forma: (1) o sistema conta a frequência de ocorrência de cada categoria de risco ao longo das 48 horas seguintes à requisição; (2) inicialmente, o risco predominante é determinado pelo risco com o maior percentual de classificações durante as 48 horas; (3) esta classificação inicial só será alterada caso, durante o período diurno, existam 6 horas consecutivas com risco 'alto' ou um somatório de 8 horas de risco 'alto' e 'moderado'; (4) se uma dessas condições críticas for atendida, o risco predominante é reclassificado para refletir essas condições críticas. Esta metodologia garante que períodos críticos não sejam subestimados, mesmo que representem uma fração menor do tempo total, seguindo uma abordagem conservadora apropriada para manejo de doenças. (Agrios, 2005; Scolin, 2023).

No caso da não apresentação de sintomas, se o risco predominante for classificado como "Elevado" ou "Alto", o sistema recomenda aplicar tratamentos preventivos alternativos, como calda bordalesa. Caso contrário, o produtor é orientado a continuar monitorando a cultura para sinais precoces da doença ou em caso de mudança de risco.

3.4.4 Etapa 3b: Manejo Corretivo Convencional/Alternativo (Sintomas Visíveis)

Se o usuário selecionar "sim", ele é guiado através de um processo multi-etapas para avaliação de severidade e ação corretiva. Primeiro, uma calculadora de amostragem, baseada em (Michereff *et al.*, 2011), determina o número de plantas e folhas a serem analisadas com base na área de cultivo. O cálculo de amostragem fornece orientação específica sobre o número de plantas a amostrar e total de folhas a coletar, com instruções visuais para padrões de amostragem diagonal do campo e coleta adequada de folhas de diferentes alturas das plantas.

Em seguida, o usuário fornece as imagens de folhas amostradas através de uma interface que suporta tanto captura de câmera quanto seleção de imagens presentes na galeria do dispositivo. A interface fornece feedback em tempo real sobre o progresso da amostragem, mostrando quantas imagens foram coletadas em relação ao tamanho de amostragem

recomendado. As imagens são então processadas através de um pipeline consistindo em pré-processamento, inferência com o modelo YOLOv8-Seg para a tarefa específica de segmentar lesões de mancha-de-cercóspora em folhas de pimenta malagueta e remoção de fundo realizada usando a biblioteca rembg. Finalmente, o sistema calcula a porcentagem média de severidade entre as imagens analisadas.

Finalmente, as recomendações são geradas através de um algoritmo de decisão integrado que combina avaliação de severidade da doença com análise de risco climático. Esta abordagem considera tanto a porcentagem média de severidade quanto o risco climático predominante para as próximas 48 horas, determinado através do método de priorização conservadora descrito anteriormente, fornecendo recomendações de manejo mais sutis e contextualmente apropriadas, divididas em quatro casos:

- **Caso 1:** *Severidade* $> 5\%$ e *risco climático elevado/alto*: Reforço da recomendação de tratamento imediato com fungicida. A aplicação sugere um período de reavaliação mais curto (3 dias) devido a condições favoráveis para progressão rápida da doença.
- **Caso 2:** *Severidade* $> 5\%$ e *risco climático baixo/moderado*: Recomendação de tratamento convencional com fungicida com maior flexibilidade de aplicação para o produtor, e indicação para reavaliação em 7 dias, uma vez que o risco de explosão epidêmica é menor.
- **Caso 3:** *Severidade* $\leq 5\%$ e *risco climático elevado/alto*: Reforço de tratamentos alternativos (por exemplo, calda bordalesa), com sugestão para reavaliação em um período mais curto (3-4 dias) para prevenir perda de controle.
- **Caso 4:** *Severidade* $\leq 5\%$ e *risco climático baixo/moderado*: Tratamentos alternativos, com reavaliação em um período mais longo (7-10 dias).

Os períodos de reavaliação estabelecidos na matriz de decisão (3 dias, 3-4 dias, 7 dias e 7-10 dias) foram fundamentados em princípios epidemiológicos estabelecidos na literatura de fitopatologia (Agrios, 2005; Del Ponte, a. o., 2005). A literatura de fitopatologia estabelece que doenças fúngicas foliares apresentam períodos de incubação relativamente curtos quando submetidas a condições favoráveis de temperatura e umidade relativa elevada (Agrios, 2005). Quando há condições climáticas favoráveis ao desenvolvimento do patógeno (risco elevado/alto) associadas à presença de sintomas, a progressão da doença tende a ser mais rápida, exigindo reavaliação em períodos mais curtos (3-4 dias) para detectar mudanças significativas na severidade e ajustar estratégias de manejo preventivamente. Por outro lado, quando as condições climáticas são menos favoráveis (risco baixo/moderado), a progressão é tipicamente mais lenta, permitindo intervalos de reavaliação mais longos (7-10 dias) sem comprometer o controle efetivo da doença (Del Ponte, a. o., 2005).

O limiar de severidade de 5% empregado nesta matriz de decisão foi estabelecido com base em níveis de dano econômico relatados em patossistemas similares para outras

culturas (Miller; Wise; Malvick, 2024; Scolin, 2023). Esta abordagem integrada fornece recomendações de manejo mais precisas e sustentáveis ao considerar tanto o status atual da doença quanto as condições ambientais que influenciam o desenvolvimento do patógeno, representando um avanço sobre critérios de decisão convencionais de parâmetro único.

Após a geração das recomendações, o sistema registra automaticamente o histórico de avaliações de severidade do usuário, armazenando informações sobre cada análise realizada, incluindo data, severidade detectada, condições climáticas avaliadas e recomendações geradas. Este histórico permite ao produtor acompanhar a evolução da doença ao longo do tempo e avaliar a eficácia das estratégias de manejo adotadas. Ao final de cada análise, o usuário pode exportar e fazer download de um arquivo PDF contendo tanto a análise atual quanto o histórico completo de avaliações anteriores, facilitando o registro documental e a análise temporal da progressão da doença na propriedade.


3.4.5 Condições de Pulverização

Quando a pulverização é recomendada, o algoritmo verifica a previsão do tempo para as próximas 48 horas para identificar a janela de tempo ideal, com base em referências técnicas (Santos *et al.*, 2013; Latin, 2021):

- Temperatura: entre 18°C e 30°C.
- Umidade relativa: entre 50% e 90%.
- Velocidade do vento: entre 3 km/h e 10 km/h.

O sistema informa ao usuário o próximo período favorável se as condições atuais não forem ideais. A Figura 30 apresenta o fluxo completo, desde a configuração inicial até a emissão da recomendação, para o caso específico da mancha-de-cercóspera.

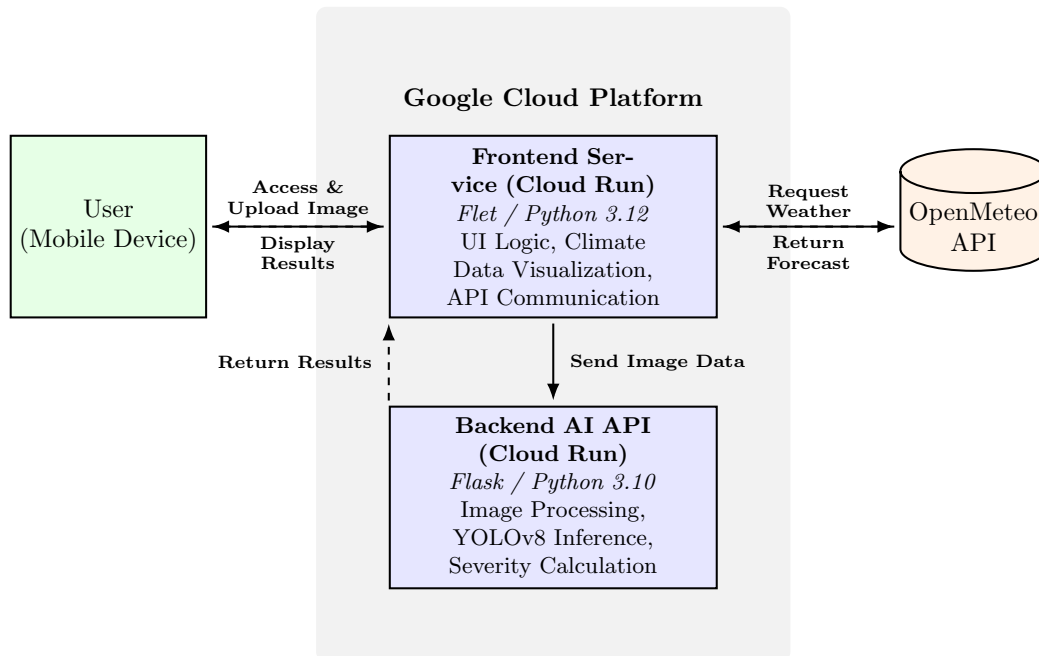
Figura 30 – Fluxograma ilustrando a lógica de decisão da aplicação FitoView para manejo de mancha-de-cercóspora em pimentas malagueta, incluindo a matriz de decisão que combina severidade detectada e risco climático para gerar os quatro casos de recomendação (Casos 1-4).



3.5 Arquitetura da Aplicação

O protótipo foi projetado como um sistema cliente-servidor, compreendendo uma aplicação *frontend* (interface do usuário) e uma API *backend* (processamento de IA), ambas implantadas na nuvem. A arquitetura geral é ilustrada na Figura 31.

Figura 31 – Arquitetura geral do sistema FitoView. Diagrama da arquitetura cliente-servidor, mostrando a interação entre o dispositivo móvel do usuário, os serviços frontend e backend implantados no Google Cloud, e a API externa OpenMeteo.



3.5.1 Implantação e Infraestrutura do Sistema

Todo o sistema está hospedado na Google Cloud Platform, utilizando a região *southamerica-east1* (São Paulo) para garantir baixa latência para usuários no Brasil. Tanto os componentes *frontend* quanto *backend* foram containerizados usando *Docker* para criar ambientes reproduzíveis e isolados. Esta abordagem baseada em contêineres simplifica a implantação e o dimensionamento, com *builds* específicos projetados para resolver potenciais conflitos de dependências entre bibliotecas como NumPy, OpenCV e PyTorch. A implantação é gerenciada através do Google Cloud Run.

3.5.2 Infraestrutura Backend: Serviço de Inferência de IA

A infraestrutura backend foi implementada em Python 3.10 usando o microframework Flask, fornecendo uma arquitetura de API RESTful com um *endpoint* `/predict` que recebe solicitações HTTP POST contendo imagens de folhas de pimenta malagueta. O serviço opera dentro de um contêiner Docker baseado em Ubuntu 22.04, garantindo implantação reproduzível e isolamento de dependências. O pipeline de processamento de imagens integra múltiplas bibliotecas Python especializadas: Flask fornece o framework do serviço web, enquanto a inferência de aprendizado profundo é executada através de um modelo Ultralytics YOLOv8 customizado e treinado. Operações de pré-processamento, incluindo redimensionamento de imagens e padronização de formato, são realizadas usando

as bibliotecas OpenCV (cv2) e Pillow (PIL). A remoção de fundo é implementada via biblioteca rembg para melhorar a precisão da segmentação de lesões ao eliminar regiões de imagem não relevantes. A execução do modelo são suportadas pelo framework de aprendizado profundo PyTorch. A implantação do Google Cloud Run para o serviço backend é configurada com recursos computacionais especificamente alocados para cargas de trabalho de inferência de IA, garantindo uma capacidade de processamento eficiente para aplicações agrícolas em tempo real.

3.5.3 Arquitetura Frontend: Aplicação Web Progressiva

A interface voltada para o usuário foi arquitetada em Python 3.12 utilizando o framework Flet, uma biblioteca moderna de desenvolvimento de aplicações multiplataforma. O serviço frontend opera dentro de um contêiner Docker leve (imagem base python:3.12-slim) e é implantado como um microserviço do Google Cloud Run com recursos alocados de 1 CPU virtual e 2GB de RAM, otimizado para fornecer interações responsivas do usuário. A aplicação segue um paradigma de Aplicação Web Progressiva (PWA), permitindo acesso direto através de navegadores web móveis modernos sem exigir instalação de aplicativo nativo, reduzindo assim barreiras de implantação para usuários finais.

A arquitetura do sistema integra múltiplas bibliotecas especializadas para fornecer funcionalidade abrangente: o framework Flet gerencia a renderização completa da interface do usuário e o gerenciamento de estado da aplicação; a aquisição de dados meteorológicos é facilitada através da biblioteca OpenMeteo-Requests para comunicação com API; a visualização de risco climático é implementada usando Matplotlib para geração programática de gráficos de avaliação de risco temporal; e a comunicação cliente-servidor para transmissão de imagens e recuperação de resultados é tratada através das bibliotecas de cliente HTTP Requests e httpx, garantindo troca de dados assíncrona robusta com o serviço de inferência backend.

3.5.4 Estimativa de Custos Operacionais e Financiamento

Para analisar a viabilidade econômica do sistema FitoView, foi realizada uma verificação dos custos operacionais associados à infraestrutura em nuvem. O modelo de precificação do Google Cloud Run baseia-se em custos variáveis de CPU e memória alocadas durante o tempo de execução dos serviços. Os custos de requisições HTTP e tráfego de rede foram desconsiderados nesta análise, pois estão dentro do tier gratuito do Google Cloud Run (2 milhões de requisições/mês) para os cenários avaliados, e representam custos negligenciáveis comparados aos custos de processamento computacional.

Além dos custos variáveis de execução, o sistema também incorre em custos fixos mensais de armazenamento: (4) Google Cloud Storage para armazenamento de arquivos e imagens, e (5) Google Artifact Registry para armazenamento de imagens Docker dos

containers do frontend e backend. O Artifact Registry é essencial para o funcionamento do Cloud Run, pois armazena as imagens Docker que são utilizadas para executar os serviços. Os custos de armazenamento são calculados por GB armazenado por mês e são independentes do número de requisições processadas, representando um custo fixo mensal que persiste mesmo em períodos de baixo uso.

A metodologia de cálculo dos custos operacionais considerou três cenários de adoção progressiva adaptados à realidade do Perímetro Irrigado Piauí, assumindo um uso médio recorrente de 6 análises mensais por produtor, baseado na frequência de reavaliação recomendada pela matriz de decisão em condições normais de cultivo. Os cenários foram: (i) cenário piloto, com 10 produtores (fase inicial de validação e difusão); (ii) cenário moderado, com 25 produtores (expansão gradual após validação inicial); e (iii) cenário ampliado, com 50 produtores (adoção mais ampla entre os produtores de pimenta malagueta do perímetro). Para cada cenário, foram analisadas áreas cultivadas de 0,1 a 0,5 ha, representativas das propriedades do perímetro. Os custos variáveis foram calculados proporcionalmente ao número de folhas processadas por análise (conforme metodologia Michereff), com tempo médio de 20 segundos por folha para processamento de imagem, inferência de IA e geração de resultados, baseado em testes realizados em campo. O serviço frontend requer aproximadamente 2-5 segundos por requisição para renderização da interface PWA, enquanto o serviço backend demanda tempo proporcional ao número de folhas processadas (300 segundos para 15 folhas em 0,1 ha, escalando linearmente para áreas maiores), valores obtidos durante os testes de validação em campo.

Os custos variáveis de execução foram calculados considerando o consumo de recursos computacionais (CPU e memória) durante o tempo de execução dos serviços. Para cada análise, foram considerados: (1) tempo de execução do backend proporcional ao número de folhas processadas (20 segundos por folha, com alocação de 2 vCPUs e 8GB de RAM), e (2) tempo de execução do frontend (aproximadamente 3 segundos por requisição, com alocação de 1 vCPU e 2GB de RAM). Os custos foram calculados multiplicando o consumo de recursos pelos preços vigentes do Google Cloud Run na região southamerica-east1 (São Paulo) em 2025: R\$ 0,00012 por vCPU-segundo e R\$ 0,0000125 por GB-segundo de memória. Os custos apresentados representam valores brutos sem considerar limites gratuitos, fornecendo uma estimativa conservadora dos custos operacionais do sistema. Os custos fixos de armazenamento (Artifact Registry e Cloud Storage) totalizam R\$ 21,60/mês e representam despesas mensais contínuas e obrigatórias, independentemente do volume de requisições ou do uso de recursos computacionais.

Este projeto de tese foi aprovado e beneficiado pelo programa Google Cloud Research Credits, que fornece créditos de infraestrutura em nuvem para projetos de pesquisa acadêmica, cobrindo tanto custos variáveis de execução quanto custos fixos de armazenamento durante o período de pesquisa. Este apoio institucional foi fundamental para viabilizar o desenvolvimento, testes e validação do sistema durante o período de pesquisa.

4 Resultados

4.1 Validação da API OpenMeteo

Em relação à temperatura média horária do ar, o modelo OpenMeteo demonstrou alta fidelidade em todas as localizações, exibindo boas associações lineares conforme evidenciado por coeficientes de correlação de Pearson (r) variando de 0,90 a 0,97 (Tabela 13). Esses valores de correlação indicam relações lineares positivas muito fortes entre os dados estimados e observados, com coeficientes de determinação correspondentes (R^2) variando de 0,81 a 0,94. O maior desempenho foi observado em Glória ($r = 0,97$; $R^2 = 0,94$), uma cidade na região semiárida, o que provavelmente é atribuível aos seus padrões atmosféricos mais estáveis e previsíveis. Além disso, os valores de RMSE para todas as cidades, 1,00 °C a 1,17 °C, alinham-se com outros estudos que realizaram a validação de dados de reanálise no Nordeste do Brasil. Por exemplo, estudos validando ERA5-Land—um modelo fundamental para a API—relataram RMSEs de temperatura do ar na faixa de 0,47 °C a 1,98 °C (Araújo *et al.*, 2025). Além disso, a validação de produtos de reanálise para aplicações agrometeorológicas frequentemente mostra magnitudes de erro similares, com RMSEs de 1–2 °C para temperatura considerados típicos e aceitáveis em simulações climáticas regionais ou comparações com medições terrestres (Mayr *et al.*, 2019; Kotlarski *et al.*, 2014; Verfaillie *et al.*, 2017).

Tabela 13 – Métricas estatísticas para a estimativa da Temperatura Média do Ar (°C) em quatro cidades de Sergipe.

Cidade	r	R^2	RMSE (°C)	MAE (°C)
Aracaju	0,90	0,81	1,15	0,86
Glória	0,97	0,94	1,00	0,69
Itabaianinha	0,94	0,89	1,17	0,89
Brejo Grande	0,93	0,86	1,13	0,87

A estimativa da umidade relativa do ar mostrou desempenho mais variado, destacando a maior complexidade da variável (Tabela 14). Os coeficientes de correlação de Pearson variaram de 0,81 a 0,95, indicando associações lineares positivas fortes a muito fortes entre valores de umidade estimados e observados. Embora o modelo tenha alcançado os melhores resultados para Glória ($r = 0,95$; $R^2 = 0,90$), seu desempenho foi comparativamente menor em Aracaju ($r = 0,81$; $R^2 = 0,65$). Esta discrepância provavelmente é atribuível à forte influência marítima na capital costeira, onde fenômenos como brisas marítimas induzem flutuações rápidas e menos previsíveis na umidade. A correlação moderada observada em Aracaju, embora menor que outras localizações, ainda indica uma relação linear substancial de acordo com a interpretação convencional do coeficiente de Pearson (Mayr *et al.*, 2019). Apesar dessa variabilidade, os valores de MAE, particularmente para Glória, Brejo Grande e Aracaju, são considerados aceitáveis e alinham-se com validações

de outros produtos de reanálise, como NASA POWER, que registrou MAE para umidade relativa entre 4% e 20% em várias localizações no Brasil (Faccin *et al.*, 2021). Similar à temperatura, erros na faixa de 5–15% para umidade relativa são frequentemente relatados em simulações climáticas regionais ou estudos comparativos com medições terrestres, e são portanto considerados típicos e aceitáveis (Mayr *et al.*, 2019; Kotlarski *et al.*, 2014; Verfaillie *et al.*, 2017).

Tabela 14 – Métricas estatísticas para a estimativa da Umidade Relativa Média (%) em quatro cidades de Sergipe.

Cidade	r	R^2	RMSE (%)	MAE (%)
Aracaju	0,81	0,65	6,72	5,25
Glória	0,95	0,90	5,85	5,85
Itabaianinha	0,86	0,75	7,90	6,18
Brejo Grande	0,90	0,81	5,88	4,48

Para radiação solar global, uma variável crucial para modelos de evapotranspiração e crescimento de culturas, os dados OpenMeteo demonstraram desempenho consistentemente forte em todas as quatro localizações, conforme mostrado na Tabela 15. Os coeficientes de correlação de Pearson variaram de 0,92 a 0,95, indicando associações lineares positivas muito fortes entre valores de radiação solar estimados e observados. Essas correlações correspondem a coeficientes de determinação ($R^2 \geq 0,84$) que demonstram a capacidade do modelo de explicar pelo menos 84% da variância nos dados de radiação observados em todas as localizações avaliadas. A consistência na força da correlação entre zonas climáticas diversas (costeira, semiárida e áreas de transição) destaca a robustez do modelo para esta variável. Os valores de MAE, variando de 0,24 MJ/m² a 0,29 MJ/m² (equivalente a 240–290 kJ/m²), são consistentes com o desempenho de outros modelos de reanálise no país. Para comparação, a validação do NASA POWER encontrou valores de MAE para radiação solar incidente variando entre 100 e 600 kJ/m² (Faccin *et al.*, 2021). A capacidade do modelo de estimar com precisão a radiação é vital, dado que a maioria das estações meteorológicas convencionais no Brasil não mede esta variável ou apresenta lacunas significativas de dados (Monteiro; Martins, 2019).

Tabela 15 – Métricas estatísticas para a estimativa da Radiação Solar Global (MJ/m²) em quatro cidades de Sergipe.

Cidade	r	R^2	RMSE (MJ/m ²)	MAE (MJ/m ²)
Aracaju	0,95	0,90	0,35	0,24
Glória	0,93	0,86	0,39	0,29
Itabaianinha	0,92	0,84	0,40	0,29
Brejo Grande	0,92	0,85	0,39	0,29

Para visualizar melhor o desempenho do modelo, gráficos de dispersão dos dados estimados versus observados foram gerados para cada variável nas quatro municipalidades.

Esses gráficos de regressão, apresentados nas Figuras 32 até 35, ilustram graficamente a relação linear, dispersão dos dados e precisão preditiva do modelo para cada zona climática específica.

A análise dos gráficos de dispersão evidencia a concordância entre os dados da API OpenMeteo e as observações do INMET. Para temperatura do ar, as linhas de regressão permanecem próximas à linha de identidade em todas as localizações, com destaque para Glória, onde a quase sobreposição visual confirma a alta correlação ($r = 0,97$). Em Aracaju, apesar da correlação ligeiramente inferior ($r = 0,90$), observa-se boa concordância ao longo de toda a faixa de valores ($\approx 20^\circ\text{C}$ a 32°C), sem indícios de viés sistemático em valores intermediários.

Para a umidade relativa, os gráficos revelam padrões discretos de distribuição, caracterizados por alinhamentos horizontais e verticais, decorrentes da resolução inteira dos dados do INMET. Aracaju apresenta maior dispersão, refletindo a maior variabilidade associada à influência marítima, enquanto Glória e Brejo Grande exibem agrupamentos mais compactos, compatíveis com correlações mais elevadas ($r = 0,95$ e $r = 0,90$).

Nos gráficos de radiação solar, observa-se leve subestimação do OpenMeteo em valores médios e altos, evidenciada por inclinações ligeiramente inferiores a 1 e interceptos positivos reduzidos. Essa diferença, no entanto, é quantitativamente pequena e acompanhada por altas correlações ($r \geq 0,92$).

A análise das equações de regressão reforça a identificação de vieses sistemáticos. Para temperatura, inclinações próximas de 1 indicam resposta proporcional aos dados de referência, com pequenas sub ou superestimações dependentes da localização. Para umidade relativa, interceptos positivos e inclinações inferiores a 1 confirmam superestimação em baixos valores e compressão em faixas elevadas. Para radiação solar, a combinação de interceptos positivos pequenos e inclinações inferiores a 1 indica subestimação crescente com o aumento da radiação.

Figura 32 – Gráficos de regressão para dados estimados (OpenMeteo) vs. observados (INMET) em Aracaju.




Figura 33 – Gráficos de regressão para dados estimados vs. observados em Brejo Grande.




Figura 34 – Gráficos de regressão para dados estimados vs. observados em Glória.






Figura 35 – Gráficos de regressão para dados estimados vs. observados em Itabaianinha.



4.2 Treinamento e Desempenho do Modelo de Detecção de Doenças YOLOv8

O treinamento do modelo de detecção de objetos YOLOv8 demonstrou características de convergência excelentes ao longo do período de treinamento de 50 épocas, conforme ilustrado na Figura 36. O processo de treinamento mostrou melhoria consistente em todas as métricas-chave de desempenho, com o modelo alcançando alta acurácia tanto em tarefas de detecção quanto de classificação.

Figura 36 – Métricas de treinamento e validação para o modelo YOLOv8-Seg ao longo de 50 épocas. Os gráficos mostram a evolução das perdas de treinamento (linha superior: `box_loss`, `cls_loss`, `dfl_loss`, precisão, recall) e métricas de validação (linha inferior: `val/box_loss`, `val/cls_loss`, `val/dfl_loss`, mAP50, mAP50-95). As linhas azuis com marcadores circulares representam os valores brutos das métricas por época, enquanto as linhas pontilhadas laranja mostram tendências suavizadas.



4.2.1 Análise de Convergência do Treinamento

As métricas de treinamento revelam uma progressão de aprendizado bem-sucedida, com todas as funções de perda mostrando declínio constante ao longo do processo de treinamento. A perda de caixa delimitadora (`box_loss`) diminuiu de um valor inicial de 1,161 para um valor final de 0,333, indicando aprendizado eficaz de localização de objetos. Similarmente, a perda de classificação (`cls_loss`) mostrou melhoria substancial, diminuindo de 3,364 para 0,320, demonstrando aprendizado bem-sucedido de classificação de doenças. A perda focal de distribuição (`dfl_loss`), que otimiza a regressão de caixa delimitadora, também exibiu melhoria consistente de 1,750 para 1,056, seguindo padrões de convergência esperados para arquiteturas baseadas em YOLO (Bochkovskiy *et al.*, 2020).

As métricas de validação seguiram tendências similares, embora com flutuações esperadas características de conjuntos de validação. Notavelmente, a perda de caixa de validação mostrou um pico inicial por volta da época 5, atingindo aproximadamente 1,7, antes de estabilizar e diminuir para cerca de 0,6 ao final do treinamento. Este comportamento reflete dinâmicas típicas de otimização em redes neurais profundas (Goodfellow *et al.*, 2016) e é consistente com padrões de convergência relatados em aplicações anteriores de CNNs para detecção de doenças de plantas (Ferentinos, 2018).

4.2.2 Desempenho do Modelo no Conjunto de Dados de Teste

O desempenho final do modelo foi avaliado em um conjunto de dados de teste independente de 49 imagens contendo 53 instâncias anotadas. Os resultados de desempenho em todas as classes de doenças são resumidos na Tabela 16.

Tabela 16 – Métricas de desempenho do modelo YOLOv8 no conjunto de dados de teste.

Classe	Precisão	Recall	F1-Score	Suporte
Mancha-de-cercóspora	1.00	1.00	1.00	9
Saudável	1.00	1.00	1.00	9
Mancha bacteriana	1.00	0.89	0.94	18
Deficiência nutricional	1.00	0.90	0.95	10
Edema	1.00	0.67	0.80	3
Média Macro	1.00	0.89	0.94	49

O modelo alcançou precisão perfeita (100%) em todas as classes de doenças, demonstrando capacidades robustas de classificação. O recall médio macro atingiu 89,11%, com F1-score de 93,77%, indicando forte desempenho geral do modelo. Notavelmente, a detecção de mancha-de-cercóspora, o foco principal deste estudo, alcançou métricas de desempenho perfeitas (100% de precisão, recall e F1-score), demonstrando a eficácia do modelo na identificação da doença-alvo.

Para fornecer uma avaliação abrangente do desempenho de classificação do modelo, matrizes de confusão foram geradas para visualizar a precisão das predições em todas as classes de doenças. A Figura 37 apresenta tanto a matriz de confusão de contagem bruta quanto a versão normalizada, oferecendo insights sobre o comportamento de classificação do modelo e padrões potenciais de má classificação.

Figura 37 – Matrizes de confusão para desempenho do modelo de detecção de objetos YOLOv8 no conjunto de dados de teste. O painel esquerdo mostra contagens brutas de predições, enquanto o painel direito exibe valores normalizados para interpretação mais fácil da precisão de classificação.




(a) Matriz de confusão de contagens brutas.

(b) Matriz de confusão normalizada.

A análise das matrizes de confusão revela que o modelo demonstra grande desempenho para a maioria das classes de doenças. Mancha-de-cercóspora e folhas saudáveis alcançaram acurácia de classificação perfeita (100%), sem falsos positivos ou falsos negativos. Mancha bacteriana mostrou alta acurácia com apenas 2 classificações incorretas de 18 instâncias, enquanto deficiência nutricional exibiu 1 classificação incorreta de 10 instâncias. A classe edema, com o menor tamanho de amostra (3 instâncias), mostrou 1 classificação incorreta, resultando no menor recall (66,67%) entre todas as classes. Esta variação de desempenho é esperada dado o caráter desbalanceado do conjunto de dados de teste, onde edema representa apenas 6,1% do total de instâncias.

Para ilustrar o desempenho prático do modelo, a Figura 38 apresenta resultados de inferência de amostra do conjunto de dados de teste, mostrando a capacidade do modelo de detectar e classificar com precisão diferentes condições de doenças em folhas de pimenta malagueta. As anotações de caixas delimitadoras exibem as predições do modelo com escores de confiança, demonstrando sua eficácia em cenários do mundo real. A figura inclui exemplos de todas as cinco classes de doenças: mancha-de-cercóspora (cercosporiose), mancha bacteriana (mancha-bacteriana), edema, deficiência nutricional (deficiência nutricional) e folhas saudáveis (saudável).

Figura 38 – Resultados de inferência de amostra do modelo YOLOv8 no conjunto de dados de teste. As caixas delimitadoras mostram previsões do modelo com escores de confiança para diferentes classes de doenças: mancha-de-cercóspora (cercosporiose), mancha bacteriana (mancha-bacteriana), edema, deficiência nutricional (deficiência nutricional) e folhas saudáveis (saudável).




A velocidade média de inferência foi medida em 15,8ms por imagem, com pré-processamento levando 9,8ms e pós-processamento exigindo 4,1ms. Esta eficiência computacional torna o modelo adequado para aplicações em tempo real em dispositivos móveis, apoiando a implantação prática do sistema de apoio à decisão.

4.3 Protótipo da Aplicação: Interface e Operação em Campo

A implementação prática e a experiência do usuário da aplicação FitoView são ilustradas através de capturas de tela da interface e validação em campo. A Figura 39 exibe uma visão sequencial da interface do usuário, destacando os principais fluxos de trabalho para gerenciar mancha-de-cercóspora em pimentas malagueta.

Figura 39 – Sequência da interface do usuário da aplicação FitoView. O fluxo de trabalho inclui: (1) Tela inicial para seleção de cultura e localização, (2) Detecção de doenças por IA ou seleção manual de lista de doenças, (3) Interface de entrada de imagem para detecção de doenças, (4) Resultados de inferência mostrando detecção de doenças com escores de confiança, (5) Painel de dados agrometeorológicos apresentando condições climáticas atuais, dados de evapotranspiração de referência, previsões de risco climático para as próximas 48 horas, botão deslizante Sim/Não e opções de avaliação de severidade. (6) Calculadora de amostragem e entrada de imagem para avaliação de severidade por IA, (7) Resultados de avaliação de severidade com análise quantitativa, e (8) Recomendações de manejo com acesso a vídeos instrucionais e receitas de preparação para caldas e soluções.




O design da interface prioriza facilidade de uso e acessibilidade para agricultores com diferentes níveis de expertise tecnológica. Cada tela fornece orientação visual clara e informações contextuais, garantindo que os usuários possam navegar efetivamente através

do processo de tomada de decisão. A tela de recomendações da aplicação (tela 8 na Figura 39) inclui acesso direto a vídeos instrucionais e arquivos PDF contendo receitas detalhadas para preparar e aplicar tratamentos, aprimorando a utilidade prática do sistema.

4.3.1 Teste em Campo e Validação Prática

Para validar a aplicabilidade prática do sistema FitoView, um teste em campo foi conduzido em um cultivo de pimenta malagueta localizado em Lagarto, Sergipe (coordenadas: 10.917°S, 37.650°W). O local de teste compreendeu um cultivo de 1 hectare dividido entre pimenta biquinho (*Capsicum chinense*) e variedades de pimenta malagueta, com a área de pimenta malagueta (0,1 ha) servindo como foco do teste.

Figura 40 – Fluxo de Trabalho do Teste de Validação em Campo.



Ao chegar ao campo, a presença de sintomas do patógeno foi visualmente confirmada, levando ao uso da aplicação FitoView para avaliação sistemática. A tela inicial foi usada para selecionar a localização e o tipo de cultura, seguida pela utilização da câmera do dispositivo móvel para identificação de doenças. O modelo de IA confirmou com sucesso a presença de mancha-de-cercóspora com um escore de confiança de 93,8%.

A avaliação de risco climático revelou a seguinte distribuição horária ao longo das 48 horas: risco baixo (43,8%), risco moderado (14,6%), risco elevado (47,7%) e risco alto (0%). Para determinar o risco predominante utilizado na matriz de decisão, foi aplicado o método descrito anteriormente. Considerando que o risco elevado ocorreu em 47,7% das horas (aproximadamente 23 horas das 48 horas), sendo o risco com o maior percentual de classificações durante as 48 horas, o sistema inicialmente classificou o risco predominante como "Elevado". Esta classificação inicial foi mantida, uma vez que não foram identificadas durante o período diurno as condições críticas que alterariam a classificação (6 horas consecutivas com risco 'alto' ou somatório de 8 horas de risco 'alto' e 'moderado'). Esta metodologia garante que o risco predominante reflita adequadamente as condições climáticas previstas, seguindo uma abordagem conservadora apropriada para manejo de doenças. Dada a presença confirmada de sintomas de mancha-de-cercóspera, a avaliação prosseguiu para avaliação de severidade usando a calculadora de amostragem integrada. Para a área de pimenta malagueta de 0,1 hectare, seguindo a metodologia Michereff previamente referenciada, a aplicação calculou o requisito para analisar 15 folhas coletadas de 5 plantas (3 folhas por planta de cada terço da planta), seguindo um padrão 'X' através do cultivo.

O processo de coleta de imagens exigiu aproximadamente 15 minutos, enquanto o tempo total de análise usando a aplicação foi de aproximadamente 5 minutos, resultando em um tempo médio de análise de 20 segundos por folha. A severidade média final foi calculada como 3,61%, que, combinada com a avaliação de risco climático (43,8% risco baixo, 14,6% risco moderado, 47,7% risco elevado, 0% risco alto), direcionou o algoritmo de decisão integrado do sistema em direção a recomendações do Caso 3: tratamento corretivo alternativo usando calda bordalesa com reavaliação sugerida em 3-4 dias devido às condições de risco climático elevado. A interface de recomendação forneceu dois pontos de acesso: um vídeo instrucional e um arquivo PDF contendo instruções detalhadas de preparação e aplicação para a calda bordalesa. Além disso, a aplicação avaliou as condições atuais de pulverização e determinou que não eram adequadas no momento da avaliação, indicando um período posterior mais favorável para tratamento. Um vídeo demonstrativo contendo o passo a passo referente ao uso da aplicação pode ser visualizado em <https://youtu.be/Cy39TfuVriA>

Esta validação em campo demonstra a viabilidade prática de traduzir detecção de doenças e avaliação de severidade baseadas em IA em decisões de manejo de campo acionáveis, apoiando o potencial do sistema para adoção generalizada em contextos agrícolas brasileiros.

4.4 Estimativas de Custos Operacionais

A Tabela 17 apresenta os custos operacionais mensais por usuário do sistema FitoView para diferentes cenários de adoção no Perímetro Irrigado Piauí, considerando uso médio

recorrente de 6 análises mensais e diferentes tamanhos de área cultivada (0,1 a 0,5 ha).

Tabela 17 – Estimativas de custos operacionais mensais do sistema FitoView para diferentes cenários de adoção no Perímetro Irrigado Piauí, considerando uso médio recorrente de 6 análises mensais por usuário e diferentes tamanhos de área cultivada (0,1 a 0,5 ha).

Cenário	Área (ha)	Folhas por análise	Custo Variável por usuário/mês (R\$)	Custo Fixo por usuário/mês (R\$)	Custo Total por usuário/mês (R\$)	Custo Total Sistema/mês (R\$)	Custo por usuário/ano (R\$)	Custo Total Sistema/ano (R\$)
Piloto (10 usuários)	0,1	15	0,615	2,160	2,775	27,75	33,30	333,00
	0,2	30	1,227	2,160	3,387	33,87	40,64	406,44
	0,3	45	1,839	2,160	3,999	39,99	47,99	479,88
	0,4	60	2,451	2,160	4,611	46,11	55,33	553,32
	0,5	75	3,063	2,160	5,223	52,23	62,68	626,76
Moderado (25 usuários)	0,1	15	0,615	0,864	1,479	36,98	17,75	443,76
	0,2	30	1,227	0,864	2,091	52,28	25,09	627,36
	0,3	45	1,839	0,864	2,703	67,58	32,44	810,96
	0,4	60	2,451	0,864	3,315	82,88	39,78	994,56
	0,5	75	3,063	0,864	3,927	98,18	47,12	1178,16
Ampliado (50 usuários)	0,1	15	0,615	0,432	1,047	52,35	12,56	628,20
	0,2	30	1,227	0,432	1,659	82,95	19,91	995,40
	0,3	45	1,839	0,432	2,271	113,55	27,25	1362,60
	0,4	60	2,451	0,432	2,883	144,15	34,60	1729,80
	0,5	75	3,063	0,432	3,495	174,75	41,94	2097,00

1

Os resultados demonstram três aspectos principais da estrutura de custos do sistema:

Economia de escala: O custo por usuário diminui significativamente com o aumento do número de usuários devido à distribuição dos custos fixos de armazenamento (R\$ 21,60/mês). No cenário piloto (10 usuários), o custo fixo por produtor é de R\$ 2,16/mês, enquanto no cenário ampliado (50 usuários), esse valor reduz para R\$ 0,43/mês, representando uma redução de 80% no custo fixo individual. Esta economia de escala torna o sistema mais viável economicamente conforme a base de usuários cresce. O custo total do sistema aumenta com o número de usuários devido aos custos variáveis adicionais, mas o custo por usuário diminui substancialmente.

Impacto do tamanho da área: O custo variável aumenta proporcionalmente com o tamanho da área cultivada, devido ao maior número de folhas processadas por análise e ao maior consumo de recursos computacionais (CPU e memória). Para uma área de 0,1 ha (15 folhas), o custo variável mensal por usuário é de R\$ 0,62, enquanto para 0,5 ha (75 folhas), esse valor aumenta para R\$ 3,06/mês, representando um incremento de 398% no componente variável. Este aumento reflete o maior tempo de processamento necessário para análises com mais folhas, resultando em maior consumo de recursos de CPU e memória.

Viabilidade econômica: Do ponto de vista do produtor individual, o custo mensal varia de R\$ 1,05/mês (R\$ 12,56/ano) no cenário mais favorável (ampliado com 50 usuários e área de 0,1 ha) a R\$ 5,22/mês (R\$ 62,68/ano) no cenário mais desfavorável (piloto com 10 usuários e área de 0,5 ha). Esta faixa de custos demonstra a viabilidade econômica do sistema para os produtores, com custos anuais variando de R\$ 12,56 a R\$ 62,68 por produtor, dependendo do cenário de adoção e tamanho da área cultivada.

Do ponto de vista do sistema como um todo, o custo total mensal varia de R\$ 27,75/mês (R\$ 333,00/ano) no cenário piloto com 10 usuários e área de 0,1 ha a R\$ 174,75/mês (R\$ 2.097,00/ano) no cenário ampliado com 50 usuários e área de 0,5 ha.

5 Discussão

5.1 Desempenho e Confiabilidade da API OpenMeteo para Aplicações Agrícolas Locais

Os resultados de validação demonstram que a API OpenMeteo fornece dados meteorológicos confiáveis para aplicações agrícolas em Sergipe, Brasil. As correlações observadas em todas as variáveis climáticas indicam a adequação da API para sistemas de apoio à decisão em regiões com cobertura limitada de estações meteorológicas. As métricas de desempenho alinham-se com benchmarks estabelecidos para validação de dados de reanálise em regiões tropicais, apoiando a integração desta fonte de dados em ferramentas de manejo agrícola.

A variação regional no desempenho da API, particularmente os resultados superiores em Glória (região semiárida) em comparação com Aracaju (costeira), destaca a importância de considerar características climáticas locais ao implementar sistemas de apoio à decisão baseados em clima. Esta descoberta é particularmente relevante para as paisagens agrícolas diversas do Brasil, onde variações microclimáticas podem impactar significativamente os padrões de desenvolvimento de doenças.

5.2 Desempenho do Modelo YOLOv8 e Relevância Clínica

O modelo de detecção de objetos YOLOv8 demonstrou grande desempenho na detecção e classificação de doenças de plantas, alcançando precisão de 100% em todas as classes de doenças e recall médio macro de 89,11%.

É importante contextualizar essas métricas elevadas considerando as características do conjunto de dados utilizado para o treinamento do modelo de classificação. Esta função foi implementada como uma funcionalidade adicional ao sistema principal de avaliação de severidade, sendo desenvolvida com datasets online reduzidos e com limitações na diversidade das amostras. O conjunto de dados utilizado apresentou pouca variação entre as amostras de treinamento e teste, o que pode ter contribuído para as métricas elevadas observadas, mas também indica uma limitação importante para a generalização do modelo em condições de campo mais diversas. Embora os resultados demonstrem a viabilidade técnica da abordagem, o desenvolvimento futuro da aplicação deve focar na construção de um conjunto de dados mais amplo e diversificado, incluindo amostras coletadas especificamente na região de interesse, para garantir maior robustez e capacidade de generalização do modelo em diferentes condições ambientais e variações fenotípicas das doenças.

A eficiência computacional do modelo, com tempos de inferência de aproximadamente 16 ms por imagem, torna-o adequado para aplicações em tempo real em dispositivos móveis. O equilíbrio entre acurácia e velocidade alcançado pela arquitetura do modelo de detecção de objetos YOLOv8 torna-o particularmente adequado para o sistema de apoio à decisão integrado proposto neste estudo.

5.3 O Protótipo no Contexto dos Ecossistemas Digitais Agrícolas Brasileiros

A paisagem de tecnologia agrícola (AgTech) no Brasil é marcadamente heterogênea, abrangendo grandes plataformas institucionais, iniciativas regionais e uma gama crescente de aplicações móveis privadas ou baseadas em comunidades. Sistemas Abrangentes de Apoio à Decisão (SIAD), como o WebAgritec da Embrapa, exemplificam a abordagem institucional, fornecendo módulos integrados para zoneamento, recomendação de cultivares, diretrizes de fertilização e diagnósticos de pragas e doenças. Embora essas plataformas forneçam cobertura ampla, frequentemente exigem entradas extensas de dados, apresentam agilidade limitada na atualização de informações e podem não ser totalmente acessíveis a pequenos agricultores devido à sua complexidade ou ao requisito de treinamento especializado.

Em contraste, o protótipo desenvolvido neste estudo foi deliberadamente concebido como uma ferramenta leve e especializada, concentrando-se na integração de dados climáticos operacionais e avaliação de severidade de doenças. Ao estreitar seu escopo, o sistema alcança agilidade, facilidade de uso e barreiras reduzidas de entrada—características essenciais para adoção entre pequenos e médios produtores que frequentemente carecem de expertise tecnológica avançada ou recursos.

Esta abordagem reflete a tendência mais ampla de diversificação dentro da AgTech brasileira, na qual aplicações móveis especializadas são cada vez mais reconhecidas por atender demandas específicas na cadeia de produção agrícola. Exemplos notáveis incluem *Plantix*, que suporta identificação de pragas e doenças através de imagens de smartphones (Haller; Quadt; Schreinemachers, 2019); *SmartCoop*, desenvolvido pela Cocamar, que integra serviços cooperativos com monitoramento de culturas (Cocamar Cooperativa Agroindustrial, 2021); e *Irrigas*, uma ferramenta que facilita o agendamento de irrigação com base em sensores de umidade do solo (Zolin; Paulino; Folegatti, 2006). Iniciativas institucionais como a plataforma *HortSenti*, desenvolvida pela Embrapa Hortaliças para monitoramento da produção de hortaliças (Embrapa Hortaliças, 2022), e sistemas regionais de alerta de pragas como *Alertas Fitossanitários da Embrapa*, que fornecem alertas para culturas incluindo pimentas malagueta (Embrapa, 2020), demonstram ainda mais como ferramentas digitais estão sendo adaptadas para sistemas de produção hortícola. Neste contexto, o FitoView ocupa um nicho complementar, democratizando o acesso à detecção de doenças baseada em IA e previsão de risco climático enquanto preserva simplicidade e acessibilidade.

Finalmente, o sistema alinha-se com os princípios de Agricultura Inteligente e Agricultura 4.0, que enfatizam a integração de tecnologias digitais para otimizar a tomada de decisão no nível da propriedade. Como tal, a ferramenta proposta não se mantém isolada, mas contribui para fortalecer o ecossistema agrícola digital do Brasil.

5.4 Inovações, Limitações Práticas e Trajetória Futura

A principal contribuição inovadora deste trabalho reside na integração de detecção de doenças e severidade baseada em CNN com previsão meteorológica em tempo real dentro de uma aplicação móvel baseada em nuvem adaptada para contextos agrícolas brasileiros. Esta abordagem cria uma ferramenta unificada de apoio à decisão que combina avaliação automatizada de severidade, análise de risco climático e recomendações práticas de manejo, demonstrando a viabilidade de traduzir modelos de IA em tecnologias acessíveis para pequenos e médios produtores.

No entanto, algumas limitações devem ser reconhecidas. Primeiro, o sistema encontra-se restrito a uma única cultura—pimenta malagueta (*Capsicum frutescens*)—e à detecção da cercosporiose. Esta limitação de escopo foi intencional para permitir desenvolvimento focado e validação robusta, mas representa restrição prática para adoção em contextos mais diversos. A expansão para outras culturas ou doenças exigirá desenvolvimento de novos conjuntos de dados robustos para cada cultura-doença específica, necessitando equipe multidisciplinar ampliada com especialistas em fitopatologia, ciência de dados, desenvolvimento de software e extensão rural.

Segundo, a dependência de conectividade com internet apresenta desafio significativo em áreas rurais remotas, onde o acesso permanece limitado ou instável, restringindo aquisição de dados meteorológicos em tempo real e inferência baseada em nuvem. Soluções híbridas podem incluir funcionalidades offline (cache temporário) ou dispositivos IoT de baixo custo para complementar previsões de API com dados climáticos capturados localmente.

Terceiro, a implantação baseada em nuvem incorre em custos operacionais contínuos que devem ser considerados na viabilidade de longo prazo do sistema. A estrutura de custos apresenta dois componentes principais: custos variáveis, que aumentam proporcionalmente com o número de análises processadas e o tamanho da área cultivada, e custos fixos de armazenamento, que representam uma despesa obrigatória e contínua independentemente do volume de uso. O alto consumo de memória do backend de inferência de IA, necessário para processar múltiplas folhas simultaneamente com modelos de aprendizado profundo, representa o principal componente dos custos variáveis. A relação entre número de usuários e custos demonstra economia de escala, onde o custo fixo por usuário diminui conforme a base de usuários cresce, tornando o sistema mais viável economicamente em cenários de adoção ampliada. Para sustentabilidade em maior escala, estratégias incluem: apoio de políticas públicas, financiamento contínuo de pesquisa, parcerias com cooperativas e associações, modelos de financiamento híbridos, e otimização de gerenciamento de imagens

Docker para reduzir custos fixos de armazenamento. Estudos futuros devem quantificar benefícios econômicos indiretos (redução de defensivos, aumento de produtividade, redução de perdas pós-colheita) para avaliação completa do retorno sobre investimento.

Pesquisas e desenvolvimentos futuros focarão em superar essas restrições e expandir as capacidades do sistema. Direções promissoras incluem integração de modelos agronômicos específicos para culturas regionais, expansão da cobertura de doenças para outras culturas economicamente importantes, e incorporação de estudos de usabilidade com design participativo. A arquitetura modular do FitoView foi projetada para facilitar essa expansão, permitindo integração de novos modelos sem reestruturação completa da plataforma, mantendo interface amigável enquanto expande progressivamente as capacidades de IA, criando um ecossistema de agricultura digital onde diferentes culturas e doenças podem ser incorporadas incrementalmente conforme recursos e dados se tornam disponíveis.

6 Conclusão

O FitoView demonstra o potencial de integrar inteligência artificial, dados climáticos e informações agronômicas em uma plataforma móvel acessível para agricultura de precisão. O sistema avança no manejo sustentável de doenças e apoia pequenos e médios agricultores no Brasil, oferecendo uma solução prática para detecção de doenças e apoio à decisão baseado em condições meteorológicas em tempo real.

Apesar de desafios como conectividade e custos, soluções como conjuntos de dados locais, funcionalidades offline e apoio de políticas podem promover a adoção. A arquitetura modular do sistema permite expansão futura para outras culturas e doenças, representando um passo importante na democratização de ferramentas de agricultura de precisão baseadas em IA para o contexto agrícola brasileiro.

Referências

AGRIOS, George N. **Plant Pathology**. 5th. San Diego, CA: Academic Press, 2005.

AGROFIT. **Consulta de Praga/Doença**. [S. l.: s. n.], 2010. Available at: https://agrofit.agricultura.gov.br/agrofit_cons/principal_agrofit_cons. (In Portuguese). Disponível em: https://agrofit.agricultura.gov.br/agrofit_cons/principal_agrofit_cons.

ALENCAR, E.R. **A história da pimenta**. [S. l.]: Embrapa, 2017. (In Portuguese). Disponível em: <https://www.embrapa.br/busca-de-noticias/-/noticia/60893663/a-historia-da-pimenta>.

ALLEN, Richard G *et al.* Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56. **Fao, Rome**, v. 300, n. 9, p. d05109, 1998.

ARAÚJO *et al.* Total precipitation and air temperature data obtained from ERA5-Land reanalysis: validation and accuracy. **Revista Caatinga**, v. 38, e12578, 2025.

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

BOCHKOVSKIY *et al.* **YOLOv4: Optimal Speed and Accuracy of Object Detection**. [S. l.: s. n.], 2020. arXiv: 2004.10934 [cs.CV]. Disponível em: <https://arxiv.org/abs/2004.10934>.

BOCK, CH *et al.* Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging. **Critical reviews in plant sciences**, Taylor & Francis, v. 29, n. 2, p. 59–107, 2010.

CARMO *et al.* Principais doenças da cultura da pimenta (Main diseases of the pepper crop). **Informe Agropecuário**, Belo Horizonte, v. 27, n. 235, p. 87–98, 2006. (In Portuguese).

CARVALHO, S.I.C. *et al.* Pimentas do gênero *Capsicum* no Brasil. Embrapa Hortaliças, Brasília, DF, 2006.

COCAMAR COOPERATIVA AGROINDUSTRIAL. **SmartCoop: Plataforma digital da Cocamar para gestão agrícola**. [S. l.: s. n.], 2021. Available online (accessed on 1 October 2025). Disponível em: <https://www.cocamar.com.br/smartcoop>.

CODERSE (COMPANHIA DE DESENVOLVIMENTO REGIONAL DE SERGIPE). **Perímetro Irrigado Piauí (Piauí Irrigation Project)**. [S. l.: s. n.], 2023. (In Por-

tuguese). Disponível em: <https://coderse.se.gov.br/perimetros/perimetros-irrigados/perimetro-irrigado-piaui-2/>.

DEL PONTE, and others. Validation of a simulation model for leaf rust epidemics in Brazilian wheat cultivars. **Phytopathology**, v. 95, n. 4, p. 487–495, 2005.

DEL PONTE, E.M. **Fitopatologia.net - herbário virtual**. [S. l.: s. n.], 2007. (In Portuguese). Disponível em: <http://www.ufrgs.br/agronomia/fitossan/herbariovirtual>.

EMBRAPA. **Alertas Fitossanitários: Sistema de avisos para manejo de pragas e doenças**. [S. l.: s. n.], 2020. Available online (accessed on 1 October 2025). Disponível em: <https://www.embrapa.br/alerta-fitossanitario>.

EMBRAPA HORTALIÇAS. **HortSenti: Plataforma digital para monitoramento da produção de hortaliças**. [S. l.: s. n.], 2022. Available online (accessed on 1 October 2025). Disponível em: <https://www.embrapa.br/hortalicas>.

FACCIN, K. *et al.* Comparison of Climate Data from NASA POWER Reanalysis and Data Measured at Surface Weather Stations for Application in Brazilian Paving Projects. **Journal of Materials in Civil Engineering**, v. 33, n. 10, 2021.

FENU, G.; MALLOCI, F.M. Forecasting plant and crop disease: an explorative study on current algorithms. **Big Data and Cognitive Computing**, v. 5, n. 1, p. 2, 2021.

FERENTINOS, K.P. Deep learning models for plant disease detection and diagnosis. **Computers and Electronics in Agriculture**, v. 145, p. 311–318, 2018.

GOODFELLOW *et al.* **Deep learning**. [S. l.]: MIT press, 2016.

HALLER, N.; QUADT, L.; SCHREINEMACHERS, P. Plantix: A mobile app for plant disease diagnosis and agricultural advisory services. **Agricultural Systems**, v. 178, p. 102760, 2019.

HIJMANS, and others. **Assessing the risk of potato late blight worldwide**. Lima, Peru, 2000.

KAMILARIS *et al.* Deep learning in agriculture: A survey. **Computers and Electronics in Agriculture**, v. 147, p. 70–90, 2018.

KAWAGOE, Hitoshi. Influence of temperature and relative humidity on disease occurrence of sweet pepper caused by *Cercospora capsici* in a plastic house. **Japanese Journal of Phytopathology**, The Phytopathological Society of Japan, v. 64, n. 2, p. 137–138, 1998.

KOTLARSKI, Sven *et al.* Regional climate modeling on European scales: a joint standard evaluation of the EURO-CORDEX RCM ensemble. **Geoscientific Model Development**, Copernicus Publications Göttingen, Germany, v. 7, n. 4, p. 1297–1333, 2014.

KRAFT, K.H. *et al.* Multiple lines of evidence for the origin of domesticated chili pepper, *Capsicum annuum*, in Mexico. **Proceedings of the National Academy of Sciences**, v. 111, n. 17, p. 6165–6170, 2014.

LATIN, R. **A Practical Guide to Turfgrass Fungicides**. [S. l.]: APS Press, 2021.

LEITE, D. **Cercospora Leaf Spot in Chili Pepper Leaves Image Dataset [Data set]**. [S. l.]: Zenodo, 2024. DOI: 10.5281/zenodo.13272039. Disponível em: <https://doi.org/10.5281/zenodo.13272039>.

LEITE, D.V.; BRITO, A.; FACCIOLI, G. *et al.* Deep Learning Models for Detection and Severity Assessment of Cercospora Leaf Spot (*Cercospora capsici*) in Chili Peppers Under Natural Conditions. **Plants**, v. 14, n. 13, p. 2011, 2025.

LEITE, Douglas; BRITO, Alisson; FACCIOLI, Gregorio. Advancements and outlooks in utilizing Convolutional Neural Networks for plant disease severity assessment: A comprehensive review. **Smart Agricultural Technology**, Elsevier, v. 9, p. 100573, 2024.

LIM, Y.S. *et al.* Sporulation of *Cercospora capsici* causing Cercospora leaf spot of pepper. **Research in Plant Disease**, v. 9, n. 3, p. 162–165, 2003.

LIU, Jun; WANG, Xuewei. Plant diseases and pests detection based on deep learning: a review. **Plant Methods**, Springer, v. 17, p. 1–18, 2021.

LOPES, C.A *et al.* **Doenças do pimentão: diagnose e controle (Sweet pepper diseases: diagnosis and control)**. Brasília, DF: Embrapa Hortaliças, 2003. (In Portuguese).

MAYR, Stefan *et al.* Validation of earth observation time-series: A review for large-area and temporally dense land surface products. **Remote Sensing**, MDPI, v. 11, n. 22, p. 2616, 2019.

MICHEREFF, S.J. *et al.* Sample size for quantification of cercospora leaf spot in sweet pepper. **Journal of Plant Pathology**, p. 183–186, 2011.

MILLER, R.; WISE, K.; MALVICK, D. **Strategic Farming: Let's talk crops focused on fungicide efficacy**. [S. l.: s. n.], 2024. Disponível em: https://blog-crop-news.extension.umn.edu/2024/03/strategic-farming-lets-talk-crops_25.html.

MOHANTY *et al.* Using deep learning for image-based plant disease detection. **Frontiers in Plant Science**, v. 7, p. 1419, 2016.

MONTEIRO, A.F.M.; MARTINS, F.B. Global Solar Radiation Models in Minas Gerais, Southeastern Brazil. **Revista Brasileira de Meteorologia**, v. 34, n. 3, p. 427–436, 2019.

NIROB, M.A.S. *et al.* **Chili Plant Leaf Disease and Growth Stage Dataset from Bangladesh**. [S. l.]: Mendeley Data, 2025. DOI: 10.17632/w9mr3vf56s.1. Disponível em: <https://doi.org/10.17632/w9mr3vf56s.1>.

NUTTER JR, F.W. *et al.* Assessing the accuracy, intra-rater repeatability, and inter-rater reliability of disease assessment systems. **Phytopathology**, v. 83, n. 8, p. 806–812, 1993.

PINTO, Cleide Maria Ferreira; TEIXEIRA, Hudson. Severidade da mancha-de-cercóspora e desempenho agrônômico da pimenta-malagueta cultivada em área de encosta em quatro épocas de plantio. **Revista Brasileira de Agropecuária Sustentável**, v. 12, n. 1, p. 183–189, 2022.

PINTO, Cleide Maria Ferreira; TEIXEIRA, Hudson; RIBEIRO, Wellington Souto. OPÇÕES PARA O CONTROLE DA CERCOSPORIOSE EM PIMENTA-MALAGUETA CULTIVADA EM ÁREA DE BAIXADA. **Revista Brasileira de Agropecuária Sustentável**, v. 12, n. 1, p. 124–133, 2022.

POPP *et al.* Pesticide productivity and food security: A review. **Agronomy for Sustainable Development**, v. 33, n. 1, p. 243–255, 2013.

RIBEIRO, C.S.C. *et al.* **Pimentas Capsicum**. Brasília, DF: Embrapa Hortaliças, 2008. (In Portuguese).

SANTOS, R.B. *et al.* PLANEJAMENTO DA PULVERIZAÇÃO DE FUNGICIDAS EM FUNÇÃO DAS VARIÁVEIS METEOROLÓGICAS NA REGIÃO DE SINOP-MT (Planning of fungicide spraying according to meteorological variables in the Sinop-MT region). **Global Science and Technology**, v. 6, n. 1, 2013. (In Portuguese).

SAVARY, S. *et al.* The global burden of pathogens and pests on major food crops. **Nature Ecology & Evolution**, v. 3, n. 3, p. 430–439, 2019.

SCOLIN, and others. Optimizing action thresholds for improved control of soybean powdery mildew with fungicides. **Tropical Plant Pathology**, v. 48, n. 2, p. 236–240, 2023.

SHI, Tingting *et al.* Recent advances in plant disease severity resoluishment using convolutional neural networks. **Scientific Reports**, Nature Publishing Group UK London, v. 13, n. 1, p. 2336, 2023.

TOO, E.C. *et al.* A comparative study of fine-tuning deep learning models for plant disease identification. **Computers and Electronics in Agriculture**, v. 161, p. 272–279, 2019.

UZHINSKIY, A. Evaluation of Different Few-Shot Learning Methods in the Plant Disease Classification Domain. **Biology**, v. 14, p. 99, 2025.

UZHINSKIY, A. *et al.* Oneshot Learning with Triplet Loss for Vegetation Classification Tasks. **Comput. Opt.**, v. 45, p. 608–614, 2021.

VERFAILLIE, Deborah *et al.* The method ADAMONT v1. 0 for statistical adjustment of climate projections applicable to energy balance land surface models. **Geoscientific Model Development**, Copernicus GmbH, v. 10, n. 11, p. 4257–4283, 2017.

ZIPPENFENIG, Patrick. Open-meteo. com weather API. **Zenodo**, 2023.

ZOLIN, C.A.; PAULINO, J.; FOLEGATTI, M.V. Irrigas: A simple tool for irrigation management. *In*: PROCEEDINGS of the International Conference on Irrigation and Drainage. [*S. l.*: *s. n.*], 2006. p. 124–129.

CAPÍTULO IV

DESAFIOS E OPORTUNIDADES PARA A IMPLEMENTAÇÃO DE TECNOLOGIAS DA AGRICULTURA 4.0 JUNTO A PEQUENOS AGRICULTORES: UMA ABORDAGEM DE ENGAJAMENTO COMUNITÁRIO E TRANSFERÊNCIA DE CONHECIMENTO NO MUNICÍPIO DE LAGARTO/SE

RESUMO

A implementação de tecnologias da Agricultura 4.0 junto a pequenos agricultores representa um desafio complexo que transcende aspectos técnicos, envolvendo dimensões sociais, econômicas e culturais. Este estudo apresenta uma abordagem de engajamento comunitário e transferência de conhecimento para a adoção de tecnologias digitais na agricultura familiar, utilizando como estudo de caso o município de Lagarto. A metodologia adotou uma abordagem qualitativa baseada em ações de divulgação e engajamento comunitário, seguindo uma perspectiva de pesquisa-ação participativa. Diferentemente de abordagens tradicionais que se baseiam exclusivamente em questionários estruturados, esta pesquisa priorizou o estabelecimento de diálogos e relações de confiança com a comunidade agrícola local, reconhecendo que a adoção de tecnologias é um processo sociotécnico que requer compreensão contextual profunda. As ações de engajamento comunitário implementadas incluíram: (i) apresentação sobre o projeto FitoView e as tecnologias da Agricultura 4.0 em reunião com agricultores no município de Lagarto/SE; (ii) entrevista para rádio local; (iii) desenvolvimento de cartilha educativa sobre o sistema e o manejo sustentável da cercosporiose em pimenta malagueta; e (iv) elaboração de vídeo demonstrativo sobre o funcionamento da plataforma. A análise dos dados foi conduzida através de reflexão sistemática fundamentada na vivência do pesquisador durante as três fases do ciclo de pesquisa-ação participativa (Look, Act e Think), identificando categorias temáticas relacionadas a desafios e oportunidades emergentes das experiências práticas vivenciadas. Os principais desafios identificados incluíram limitações de conectividade, necessidade de capacitação digital e barreiras econômicas. As oportunidades identificadas incluíram

alta penetração de smartphones, interesse demonstrado pelos agricultores, potencial de parcerias com organizações locais (CODERSE, APPIP, MCP), demanda por ferramentas que reduzam uso de agrotóxicos e existência de canais de comunicação locais estabelecidos. Os resultados destacam a importância crítica de intermediários confiáveis no processo de transferência de tecnologia e a necessidade de abordagens participativas e dialógicas que construam confiança e adaptem tecnologias às realidades locais. Este estudo contribui para a compreensão dos processos sociotécnicos de adoção de tecnologias agrícolas digitais em contextos de agricultura familiar e oferece diretrizes para transferência de tecnologia em contextos similares.

Palavras-chave: Agricultura 4.0; Agricultura Familiar; Transferência de Tecnologia; Engajamento Comunitário; Adoção de Tecnologias; Pequenos Agricultores

CHALLENGES AND OPPORTUNITIES FOR IMPLEMENTING AGRICULTURE 4.0 TECHNOLOGIES WITH SMALL FARMERS: A COMMUNITY ENGAGEMENT AND KNOWLEDGE TRANSFER APPROACH IN LAGARTO MUNICIPALITY

ABSTRACT

The implementation of Agriculture 4.0 technologies with small farmers represents a complex challenge that transcends technical aspects, involving social, economic, and cultural dimensions. This study presents a community engagement and knowledge transfer approach for the adoption of digital technologies in family farming, using Lagarto municipality as a case study. The methodology adopted a qualitative approach based on dissemination and community engagement actions, following a participatory action-research perspective. Unlike traditional approaches that rely exclusively on structured questionnaires, this research prioritized the establishment of dialogues and trust relationships with the local agricultural community, recognizing that technology adoption is a sociotechnical process that requires deep contextual understanding. The community engagement actions implemented included: (i) presentation on the FitoView project and Agriculture 4.0 technologies at a meeting of the Movimento Camponês Livre (MCP) in Lagarto/SE; (ii) interview on the "Raízes e Sons da Terra" program on local radio Lagarto FM; (iii) development of an educational booklet on the FitoView system and sustainable management of cercospora leaf spot in malagueta pepper; and (iv) creation of a demonstrative video on the platform's functioning. Data analysis was conducted using content analysis, identifying thematic categories related to challenges and opportunities. The main challenges identified included connectivity limitations, need for digital training, and economic barriers. The opportunities identified included high smartphone penetration, interest demonstrated by farmers, potential for partnerships with local organizations (CODERSE, APPIP, MCP), demand for tools that reduce pesticide use, and existence of established local communication channels. The results highlight the critical importance of trusted intermediaries in the technology transfer process and the need for participatory and dialogical approaches that build trust and adapt technologies to local realities. This study contributes to understanding sociotechnical processes of adoption of digital agricultural technologies in family farming contexts and offers guidelines for technology transfer in similar contexts.

Keywords: Agriculture 4.0; Family Farming; Technology Transfer; Community Engagement; Technology Adoption; Small Farmers

1 Introdução

A agricultura familiar desempenha papel fundamental no abastecimento alimentar do Brasil, sendo responsável por 77% dos estabelecimentos agrícolas e empregando 67% da força de trabalho agropecuária (IBGE, 2019). Além disso, é responsável por aproximadamente 38% do valor bruto da produção agropecuária nacional e por mais de 50% dos alimentos consumidos no país (IBGE, 2019). No entanto, os pequenos agricultores enfrentam desafios significativos para a adoção de tecnologias inovadoras, incluindo limitações de conectividade, falta de capacitação digital, custos elevados de implementação e soluções que frequentemente não consideram suas necessidades específicas (Barrett *et al.*, 2021; Proença *et al.*, 2015).

A chamada quarta revolução tecnológica, caracterizada pela convergência de tecnologias digitais, físicas e biológicas, tem transformado profundamente os sistemas produtivos, incluindo a agricultura (Schwab, 2017). A Agricultura 4.0 incorpora tecnologias avançadas como Internet das Coisas (IoT), inteligência artificial, big data e análise massiva de dados, possibilitando monitoramento em tempo real, automação de processos e tomada de decisões baseada em evidências (Weersink *et al.*, 2021). No entanto, a implementação dessas tecnologias junto a pequenos agricultores representa um desafio complexo que transcende aspectos técnicos, envolvendo dimensões sociais, econômicas e culturais (Baumüller, 2018).

Estudos sobre adoção de tecnologia em contextos rurais destacam que a disposição dos agricultores para integrar inovações depende não apenas da utilidade percebida, mas também de acessibilidade, custo e confiança estabelecida através de atividades de extensão participativas (Rogers, 2003; Feder; Umali, 1993). No Brasil, pesquisas indicam que pequenos agricultores frequentemente enfrentam barreiras relacionadas à alfabetização digital e infraestrutura, ainda demonstram forte interesse quando tecnologias são contextualizadas para suas realidades de produção e apresentadas através de intermediários confiáveis, como cooperativas e agentes de extensão (Proença *et al.*, 2015; Barrett *et al.*, 2021).

A teoria da difusão de inovações de Rogers fornece um framework útil para entender os fatores que influenciam a adoção de tecnologias por agricultores (Rogers, 2003). Segundo esta teoria, a adoção de uma inovação depende de características como vantagem relativa, compatibilidade com valores e necessidades existentes, complexidade percebida, possibilidade de experimentação e observabilidade dos resultados (Rogers, 2003). Para tecnologias agrícolas digitais, a simplicidade de uso, o baixo custo, a compatibilidade com dispositivos existentes e a demonstração clara de benefícios são fatores críticos para a adoção por pequenos agricultores (Barrett *et al.*, 2021).

Este estudo apresenta uma abordagem de engajamento comunitário e transferência de conhecimento para a adoção do sistema FitoView, uma tecnologia da Agricultura 4.0 desenvolvida especificamente para apoiar o manejo da cercosporiose em pimenta malagueta. O sistema é uma plataforma de apoio à decisão móvel que integra redes

neurais convolucionais para detecção automática de doenças e sua severidade com previsão meteorológica em tempo real, oferecendo recomendações contextualizadas de manejo aos agricultores. Utilizando como estudo de caso o município de Lagarto, este trabalho tem como objetivo identificar desafios e oportunidades para a implementação da tecnologia junto aos pequenos agricultores do município, através de uma abordagem qualitativa baseada em ações de divulgação e engajamento comunitário.

2 Metodologia

2.1 Abordagem Metodológica

Este estudo adotou uma abordagem qualitativa baseada em pesquisa-ação participativa (Stringer, 2014). A metodologia seguiu o ciclo iterativo de três etapas proposto pelo autor: Look (observar e compreender o contexto), Act (agir e transformar) e Think (analisar e interpretar).

Os princípios fundamentais aplicados em todas as fases incluíram participação da comunidade agrícola local, estabelecimento de diálogos e relações de confiança, adaptação das tecnologias às realidades locais, e busca por soluções práticas e aplicáveis.

2.2 Fase Look: Visita Inicial e Identificação do Problema

O processo de identificação do problema teve início com uma visita exploratória ao Perímetro Irrigado Piauí, localizado no município de Lagarto/SE, realizada em 30 de Janeiro de 2023. Esta visita teve como objetivo estabelecer contato inicial com técnicos da CODERSE e agricultores do município, compreender o contexto produtivo e identificar problemas fitossanitários prioritários.

Durante a visita, foi realizado um encontro com técnicos agrícolas da CODERSE, responsáveis pelo suporte técnico aos agricultores do perímetro irrigado. Os técnicos relataram que a cercosporiose (*Cercospora capsici*) representava um dos principais desafios fitossanitários enfrentados pelos produtores de pimenta malagueta no município, causando perdas recorrentes de produção e levando ao uso periódico de fungicidas como tentativa de contenção da doença.

Posteriormente, foi realizada uma visita em campo a uma área de cultivo de pimenta malagueta, onde foi possível observar diretamente os sintomas da cercosporiose nas plantas e dialogar com agricultores sobre suas práticas de manejo. Os agricultores relataram dificuldades na identificação precoce da doença e na determinação do momento adequado para aplicação de tratamentos, frequentemente recorrendo a aplicações preventivas ou baseadas em calendário, o que resultava em uso excessivo de defensivos agrícolas.

Esta visita inicial foi fundamental para: (i) identificar a cercosporiose como problema prioritário a ser abordado; (ii) compreender o contexto produtivo e as práticas de ma-

nejo existentes; (iii) estabelecer relações de confiança com técnicos e agricultores; e (iv) fundamentar o desenvolvimento da plataforma, que viria a ser desenvolvida nos artigos anteriores desta tese especificamente para apoiar o manejo desta doença. A Figura 41 ilustra momentos desta visita inicial.

Figura 41 – Visita inicial ao Perímetro Irrigado Piauí para identificação do problema da cercosporiose e estabelecimento de contato com técnicos e agricultores.



(a) Contato inicial com agricultor durante visita ao Perímetro Irrigado Piauí.



(b) Observação dos sintomas da cercosporiose em folhas de pimenta malagueta durante a visita em campo.

2.3 Fase Act: Desenvolvimento Técnico e Ações de Engajamento Comunitário

2.3.1 Desenvolvimento da Plataforma FitoView

Com base na compreensão contextual obtida na primeira fase, foi desenvolvida a plataforma FitoView, um sistema de apoio à decisão móvel que integra redes neurais convolucionais para detecção automática de doenças com previsão meteorológica em tempo real. O desenvolvimento técnico da plataforma, incluindo validação de dados meteorológicos, desenvolvimento de modelos CNN customizados e implementação da aplicação web progressiva, foi detalhado nos Artigos II e III desta tese. Esta etapa representou a ação técnica de criação da solução tecnológica, fundamentada nas necessidades identificadas durante a fase Look.

2.3.2 Ações de Engajamento Comunitário

Após o desenvolvimento técnico da plataforma, foram implementadas ações de engajamento comunitário para apresentação e divulgação da tecnologia desenvolvida. Estas ações visaram transferir conhecimento e facilitar a adoção da tecnologia pela comunidade agrícola local através de múltiplos canais de comunicação.

2.3.2.1 Apresentação no Movimento Camponês Livre (MCP)

Em novembro de 2025, foi realizada uma apresentação sobre o sistema FitoView e as tecnologias da Agricultura 4.0 em uma reunião do Movimento Camponês Livre (MCP) em Lagarto/SE. A reunião contou com a participação de aproximadamente 30-40 agricultores familiares, técnicos agrícolas, lideranças comunitárias e agentes financiadores.

A apresentação incluiu: (i) contextualização sobre a Agricultura 4.0 e suas potencialidades para a agricultura familiar; (ii) explicação detalhada da plataforma, suas funcionalidades de detecção automática de cercosporiose e geração de recomendações de manejo baseadas em dados meteorológicos; (iii) discussão sobre os benefícios potenciais do sistema, incluindo redução do uso de agrotóxicos e melhoria do manejo fitossanitário; e (iv) espaço para perguntas, dúvidas e sugestões dos participantes sobre o uso e aplicação da ferramenta. A Figura 42 ilustra o momento da apresentação.

Figura 42 – Apresentação da plataforma em reunião do Movimento Camponês Livre (MCP) em Lagarto/SE, com participação de agricultores familiares, técnicos e lideranças comunitárias.



2.3.2.2 Entrevista em Rádio Local

Em setembro de 2025, foi realizada uma entrevista no programa "Raízes e Sons da Terra" da rádio local Lagartto FM, uma estação que serve como importante canal de

comunicação para a comunidade local, especialmente para agricultores que frequentemente sintonizam programas relacionados à agricultura e desenvolvimento rural.

A entrevista foi conduzida em formato de programa de rádio, com duração aproximada de 30 minutos, abordando os seguintes temas: (i) apresentação do projeto de pesquisa e do sistema FitoView; (ii) explicação sobre como a inteligência artificial da plataforma pode auxiliar no manejo de doenças de plantas através da detecção automática e quantificação da severidade; (iii) discussão sobre os benefícios do sistema para pequenos agricultores, incluindo redução de custos e uso de agrotóxicos através de recomendações mais precisas; e (iv) informações sobre como acessar e utilizar a aplicação através de smartphones. As perguntas foram realizadas pelo apresentador do programa, que faz parte do corpo técnico da CODERSE, durante a entrevista.

A rádio Lagartto FM possui alcance regional, alcançando agricultores em áreas rurais que podem não ter acesso fácil a outras formas de informação tecnológica. A Figura 43 mostra o momento da entrevista no estúdio da rádio.

Figura 43 – Entrevista sobre a plataforma no programa "Raízes e Sons da Terra" da rádio local Lagartto FM, importante canal de comunicação para agricultores do município de Lagarto/SE.



2.3.2.3 Desenvolvimento de Cartilha Educativa

Foi desenvolvida uma cartilha educativa sobre o uso da plataforma e o manejo sustentável da cercosporiose em pimenta malagueta, destinada à distribuição junto a agricultores, técnicos da CODERSE e membros da APPIP. A cartilha foi elaborada com linguagem acessível e ilustrações didáticas, utilizando uma narrativa baseada em caso prático (exemplo do agricultor José) para facilitar a compreensão, considerando diferentes níveis de alfabetização e familiaridade com tecnologias digitais.

A cartilha apresenta o sistema FitoView como um "ajudante digital no combate a doenças" e inclui as seguintes seções: (i) apresentação do problema da cercosporiose e seus impactos na produção (manchas escuras nas folhas, queda prematura, perda de produção e prejuízos na renda); (ii) descrição das funcionalidades principais da plataforma, incluindo identificação de doenças por foto, análise de risco climático e recomendações de tratamento; (iii) passo a passo ilustrado e detalhado para utilização do sistema; (iv) explicação sobre as recomendações geradas pela aplicação; (v) explicação de recursos adicionais disponíveis na plataforma; (vi) informações de contato e suporte técnico.

A cartilha foi desenvolvida em formato físico (impresso) e digital (PDF), permitindo acesso através de smartphones e compartilhamento via aplicativos de mensagem. A distribuição está sendo realizada em formato físico e digital com a ajuda da CODERSE e APPIP. A Figura 44 apresenta páginas da cartilha educativa desenvolvida.

Figura 44 – Páginas da cartilha educativa sobre a plataforma e manejo sustentável da cercosporiose em pimenta malagueta, desenvolvida para distribuição junto a agricultores, técnicos da CODERSE e membros da APPIP.



(a) Primeira página da cartilha



(b) Segunda página da cartilha

2.3.2.4 Desenvolvimento de Vídeo Demonstrativo

Por fim, foi elaborado um vídeo demonstrativo sobre a plataforma, disponível em plataforma de compartilhamento de vídeos online. O vídeo apresenta uma demonstração prática do funcionamento do sistema, incluindo: (i) explicação sobre as funcionalidades principais da aplicação, destacando a integração entre detecção automática de doenças e previsão meteorológica; (ii) demonstração passo a passo de como utilizar a ferramenta através de smartphones para detecção de cercosporiose; (iii) exemplos práticos de análise de severidade em folhas de pimenta malagueta utilizando o sistema; e (iv) apresentação das recomendações de manejo geradas pela plataforma baseadas na severidade detectada e condições climáticas previstas.

O vídeo foi desenvolvido com linguagem acessível e visualização clara das telas da aplicação. A Figura 45 apresenta uma captura de tela do vídeo demonstrativo, disponível em: <https://youtu.be/Cy39TfuVriA>.

Figura 45 – Captura de tela do vídeo demonstrativo da plataforma, disponível em: <https://youtu.be/Cy39TfuVriA>



2.4 Fase Think: Análise dos Dados e Identificação de Categorias

A fase *Think* do ciclo de pesquisa-ação participativa compreendeu a análise reflexiva e sistematização dos resultados obtidos durante as ações de engajamento comunitário (fase Act), fundamentada na experiência vivenciada pelo pesquisador ao longo das três fases do ciclo. Esta fase seguiu um processo sistemático de reflexão sobre as experiências práticas: (i) organização e sistematização das informações coletadas durante as ações de engajamento, com base nas observações e interações vivenciadas; (ii) identificação de padrões e categorias temáticas relacionadas a desafios e oportunidades, emergentes da experiência prática do pesquisador; (iii) análise e interpretação reflexiva dos dados à luz dos objetivos do estudo e do referencial teórico sobre adoção de tecnologias; e (iv) discussão

dos resultados contextualizando limitações e oportunidades para a adoção de tecnologias agrícolas no município.

As categorias de análise foram construídas a partir da reflexão sistemática sobre múltiplas experiências vivenciadas durante a fase Act: (i) observações diretas durante as apresentações e reuniões, onde o pesquisador pôde perceber reações, dúvidas e interesses dos participantes; (ii) perguntas e comentários dos participantes que revelaram preocupações e expectativas; (iii) interações durante a entrevista de rádio que permitiram identificar questões relevantes para a comunidade; (iv) feedback informal de técnicos e lideranças comunitárias que trouxeram perspectivas complementares; e (v) processo de desenvolvimento de materiais educativos (cartilha e vídeo demonstrativo) que revelou necessidades de informação e formatos preferidos pelos agricultores através da prática de criação e ajuste dos materiais.

Através da reflexão sistemática sobre essas experiências vivenciadas, foram identificadas sete categorias temáticas principais, organizadas em duas dimensões: *Desafios para Adoção* (limitações de conectividade, necessidade de capacitação digital, barreiras econômicas) e *Oportunidades para Adoção* (alta penetração de smartphones, interesse demonstrado pelos agricultores, potencial de parcerias com organizações locais, demanda por ferramentas que reduzam uso de agrotóxicos). Estas categorias emergiram de forma recorrente e consistente nas diferentes experiências vivenciadas pelo pesquisador e foram validadas através da triangulação entre observações diretas, interações formais e desenvolvimento de materiais educativos, garantindo robustez na identificação dos temas centrais relacionados à adoção da tecnologia.

3 Resultados

Esta seção apresenta os resultados da fase *Think*, sistematizando as sete categorias temáticas identificadas através da reflexão sistemática sobre as experiências vivenciadas pelo pesquisador durante as fases metodológicas. As categorias são organizadas em duas dimensões principais: desafios e oportunidades para adoção da tecnologia, emergentes da análise reflexiva das interações, observações e desenvolvimento de materiais realizados ao longo do processo de engajamento comunitário.

3.1 Desafios Identificados para Adoção de Tecnologias

3.1.1 Limitações de Conectividade

Um dos principais desafios identificados refere-se às limitações de conectividade à internet nas áreas rurais do município. Durante as apresentações, alguns agricultores relataram dificuldades de acesso à internet em suas propriedades, especialmente em áreas

mais afastadas do centro urbano. A conectividade é frequentemente limitada a pontos específicos ou depende de dados móveis, que podem ser caros e ter cobertura irregular.

Esta limitação representa um desafio significativo para tecnologias baseadas em nuvem, como a plataforma desenvolvida, que requer conexão à internet para processamento de imagens e acesso a dados meteorológicos. Agricultores expressaram preocupação sobre a viabilidade de uso da ferramenta em condições de conectividade precária ou intermitente.

3.1.2 Necessidade de Capacitação Digital

Outro desafio importante identificado foi a necessidade de capacitação digital dos agricultores. Durante as apresentações, observou-se que alguns agricultores demonstravam familiaridade limitada com smartphones e aplicativos. Embora a maioria possua smartphones, o uso frequentemente se limita a chamadas telefônicas, mensagens de texto e redes sociais básicas.

A utilização de tecnologias mais complexas, como aplicativos de análise de imagens, requer um nível de familiaridade tecnológica que nem todos os agricultores possuem. Foi identificada a necessidade de treinamentos práticos e materiais educativos que facilitem o aprendizado gradual, começando com funcionalidades básicas e progredindo para usos mais avançados.

3.1.3 Barreiras Econômicas

Questões econômicas também foram mencionadas como barreiras potenciais. O funcionamento da plataforma depende do uso de serviços de nuvem (Google Cloud), o que pode gerar custos operacionais. Agricultores expressaram preocupações sobre custos indiretos, como: (i) necessidade de planos de dados móveis mais robustos; (ii) possível necessidade de atualização de smartphones para modelos mais recentes; e (iii) tempo necessário para aprendizado e uso da ferramenta, que pode competir com outras atividades produtivas.

3.2 Oportunidades Identificadas

3.2.1 Alta Penetração de Smartphones

Uma oportunidade significativa identificada foi a alta penetração de smartphones entre os agricultores do município. Durante as apresentações, observou-se que praticamente todos os agricultores presentes possuíam smartphones, e muitos já utilizam aplicativos básicos em suas atividades diárias. Esta infraestrutura tecnológica existente representa uma base sólida para adoção de tecnologias agrícolas digitais.

A familiaridade com smartphones, mesmo que básica, reduz barreiras de entrada para tecnologias móveis, tornando mais viável a adoção de aplicativos agrícolas quando comparado a tecnologias que requerem equipamentos especializados ou computadores.

3.2.2 Interesse Demonstrado pelos Agricultores

Durante as apresentações e interações, observou-se interesse genuíno dos agricultores em soluções práticas que possam melhorar suas atividades produtivas. Especialmente quando demonstradas aplicações práticas, como a detecção de doenças em tempo real. Além disso, os agricultores demonstraram particular interesse na obtenção de dados climáticos, principalmente informações sobre precipitação (chuva), que são fundamentais para o planejamento das atividades agrícolas e manejo de irrigação.

Muitos agricultores fizeram perguntas específicas sobre como a tecnologia poderia ser aplicada em suas propriedades, indicando que percebem valor potencial na solução. Este interesse representa uma oportunidade importante para processos de adoção gradual e experimental.

3.2.3 Potencial de Parcerias com Organizações Locais

A existência de organizações locais bem estabelecidas, como CODERSE, APPIP e MCP, representa uma oportunidade significativa para processos de transferência de tecnologia. Essas organizações possuem credibilidade e relações de confiança estabelecidas com os agricultores, podendo atuar como intermediários confiáveis na introdução de novas tecnologias.

Durante as interações, técnicos da CODERSE e lideranças da APPIP demonstraram interesse em apoiar a disseminação da tecnologia, oferecendo canais para treinamentos, distribuição de materiais e acompanhamento do uso. Estas parcerias podem facilitar significativamente processos de adoção.

3.2.4 Demanda por Ferramentas que Reduzam Uso de Agrotóxicos

Uma oportunidade particularmente relevante identificada foi a demanda expressa por ferramentas que reduzam o uso de agrotóxicos. Agricultores relataram preocupações sobre custos elevados de defensivos agrícolas e impactos ambientais e à saúde. A promessa da plataforma de permitir aplicações mais precisas e direcionadas, reduzindo uso desnecessário de agrotóxicos, ressoou fortemente com os agricultores.

Esta demanda alinha-se com tendências mais amplas de busca por práticas agrícolas mais sustentáveis e representa um motivador importante para adoção da tecnologia.

4 Discussão

A análise dos resultados deste estudo revela que a adoção de tecnologias agrícolas digitais em contextos de agricultura familiar é fundamentalmente um processo sociotécnico, onde aspectos técnicos e sociais estão intrinsecamente interligados (Feder; Umali, 1993). É importante lembrar que os pequenos agricultores enfrentam desafios significativos

para a adoção de tecnologias inovadoras, incluindo limitações de conectividade, falta de capacitação digital, custos elevados de implementação e soluções que frequentemente não consideram suas necessidades específicas (Barrett *et al.*, 2021; Proença *et al.*, 2015). A implementação dessas tecnologias junto a pequenos agricultores representa um desafio complexo que transcende aspectos técnicos, envolvendo dimensões sociais, econômicas e culturais (Baumüller, 2018).

Um aspecto relevante observado durante o processo de engajamento foi a abertura demonstrada pelos agricultores para dialogar com pesquisadores e compartilhar suas experiências, preocupações e conhecimentos tradicionais. Esta receptividade foi fundamental para estabelecer relações de confiança e compreender as necessidades reais da comunidade agrícola local. A experiência demonstrou que agricultores estão dispostos a participar de processos de inovação quando percebem que suas vozes são valorizadas e que as tecnologias desenvolvidas consideram suas realidades específicas. Esta abertura para o pesquisador por parte dos agricultores facilitou significativamente o processo de transferência de conhecimento e permitiu adaptações importantes no desenvolvimento e apresentação da plataforma.

Os resultados também destacam a importância crítica de intermediários confiáveis no processo de transferência de tecnologia. A experiência das ações de engajamento demonstrou que organizações locais como CODERSE, APPIP e MCP possuem relações de confiança estabelecidas com os agricultores e podem facilitar significativamente processos de adoção, atuando como tradutores culturais que adaptam linguagens técnicas para contextos locais e criam pontes entre diferentes sistemas de conhecimento.

A abordagem metodológica adotada, revelou insights valiosos sobre necessidades, preocupações e expectativas dos agricultores que dificilmente seriam capturados através de métodos mais tradicionais. Os espaços de diálogo criados durante as ações de engajamento permitiram que agricultores expressassem preocupações, fizessem sugestões e compartilhassem conhecimentos tradicionais relevantes. Esta experiência demonstra que abordagens participativas e dialógicas são essenciais para processos efetivos de transferência de tecnologia, reconhecendo agricultores como co-produtores de conhecimento e não apenas receptores passivos de tecnologias desenvolvidas externamente (Stringer, 2014).

A análise revela que tecnologias desenvolvidas em contextos de pesquisa frequentemente requerem adaptação significativa para serem efetivas em contextos de agricultura familiar. O desenvolvimento da cartilha educativa e as adaptações na apresentação da plataforma durante as reuniões representaram tentativas de tornar a tecnologia mais acessível e contextualizada para o público-alvo, reconhecendo que aspectos como linguagem, formato e canais de comunicação são tão importantes quanto características técnicas da solução.

É importante reconhecer limitações da abordagem metodológica adotada. A ausência de questionários estruturados em larga escala limita a generalização quantitativa dos resultados. As observações e interações, embora valiosas, representam uma amostra não

aleatória e podem não capturar toda a diversidade de percepções e experiências dos agricultores do município. Além disso, as ações de engajamento foram realizadas em um período relativamente curto, e não foi possível acompanhar processos de adoção de longo prazo.

A avaliação da efetividade das estratégias de transferência de tecnologia requereria estudos longitudinais que acompanhem agricultores ao longo de múltiplos ciclos produtivos para compreender como tecnologias são adaptadas e reinterpretadas após uso inicial.

Uma dificuldade prática significativa enfrentada durante o processo foi que, apesar das parcerias estabelecidas com organizações locais, a reunião de um número significativo de agricultores e a adesão dos mesmos nas reuniões para apresentação se apresentou como uma tarefa complexa, dada a rotina de cada agricultor e suas múltiplas responsabilidades produtivas e familiares. Mesmo assim, foi possível estabelecer alguma troca com eles através dos diferentes canais de comunicação utilizados, incluindo reuniões presenciais, entrevista em rádio local e materiais educativos distribuídos.

Os resultados têm implicações importantes para políticas públicas de apoio à adoção de tecnologias digitais na agricultura familiar. Investimentos em infraestrutura de conectividade rural e programas de capacitação digital são necessários, mas não suficientes. Políticas que apoiem organizações locais que atuam como intermediários e incentivem parcerias entre universidades, organizações de pesquisa e organizações de agricultores podem criar sinergias que facilitem processos de transferência de tecnologia mais efetivos. Além disso, políticas de desenvolvimento tecnológico devem priorizar processos participativos de co-design que incorporem desde o início perspectivas e necessidades de agricultores familiares, garantindo que tecnologias sejam desenvolvidas especificamente para este contexto ao invés de adaptadas posteriormente.

É importante ponderar que a plataforma desenvolvida neste estudo representa um protótipo funcional que demonstra a viabilidade técnica e potencial de aplicação das tecnologias da Agricultura 4.0 em contextos de agricultura familiar. No entanto, para que o sistema alcance seu pleno potencial e possa ser efetivamente adotado em escala, será necessária a formação de uma equipe multidisciplinar a posteriori para realizar melhoramentos contínuos, adicionar novas doenças e culturas, desenvolver funcionalidades adicionais baseadas no feedback dos usuários, e garantir suporte técnico adequado para os agricultores.

Esta evolução do protótipo para uma solução robusta e escalável requer investimentos em desenvolvimento, manutenção e capacitação que vão além do escopo inicial desta pesquisa, mas que são essenciais para a sustentabilidade e efetividade de longo prazo da tecnologia.

5 Conclusão

Este estudo demonstrou que a implementação de tecnologias da Agricultura 4.0 junto a pequenos agricultores requer abordagens que transcendem aspectos técnicos, incorporando dimensões sociais e culturais do processo de adoção. A experiência de engajamento comunitário desenvolvida no município de Lagarto evidenciou que a receptividade dos agricultores e a presença de intermediários confiáveis são fatores determinantes para o sucesso de processos de transferência de tecnologia.

As ações de divulgação implementadas permitiram identificar tanto barreiras estruturais quanto potencialidades significativas para adoção de tecnologias digitais na agricultura familiar. A análise dos resultados reforça a importância de processos participativos que reconheçam agricultores como co-produtores de conhecimento, adaptando tecnologias às realidades locais através de diálogos e relações de confiança.

Referências

- BARRETT, C.B. *et al.* On the structural transformation of rural Africa. **World Development**, v. 142, p. 105454, 2021.
- BAUMÜLLER, Heike. The little we know: An exploratory literature review on the utility of mobile phone-enabled services for smallholder farmers. **Journal of International Development**, Wiley Online Library, v. 30, n. 1, p. 134–154, 2018.
- FEDER, G.; UMALI, D.L. The adoption of agricultural innovations: A review. **Technological Forecasting and Social Change**, v. 43, n. 3–4, p. 215–239, 1993.
- IBGE. **Censo Agropecuário 2017: resultados definitivos**. Rio de Janeiro: IBGE, 2019.
- PROENÇA *et al.* Tecnologias da informação e comunicação e a agricultura familiar: Desafios e perspectivas. **Revista de Economia e Sociologia Rural**, v. 53, n. 1, p. 85–102, 2015.
- ROGERS, E.M. **Diffusion of Innovations**. 5th. New York, USA: Free Press, 2003.
- SCHWAB, Klaus. **The Fourth Industrial Revolution**. New York: Crown Business, 2017.
- STRINGER, Ernest T. **Action Research**. 4. ed. Los Angeles: SAGE Publications, 2014.
- WEERSINK, Alfons *et al.* Opportunities and challenges for big data in agricultural and environmental analysis. **Annual Review of Resource Economics**, Annual Reviews, v. 10, p. 19–37, 2021.

8 Conclusão Geral

Esta tese teve como objetivo geral promover a utilização de redes neurais convolucionais integradas a dados de previsão climática para a detecção automática, quantificação da severidade e apoio ao manejo sustentável da cercosporiose no cultivo da pimenta malagueta. O desenvolvimento da pesquisa, estruturado em uma abordagem metodológica integrada de natureza quali-quantitativa, proporcionou contribuições científicas, tecnológicas e sociais, articulando diferentes dimensões necessárias à implementação de tecnologias da Agricultura 4.0 em contextos de agricultura familiar.

A revisão sistemática da literatura consolidou o estado da arte na utilização de redes neurais convolucionais para avaliação da severidade de doenças em plantas, identificando tendências metodológicas, lacunas de conhecimento e direções promissoras que fundamentaram o desenvolvimento dos modelos propostos. O desenvolvimento e validação de modelos customizados de aprendizado profundo baseados em arquiteturas Mask R-CNN e YOLOv8 demonstraram viabilidade técnica para detecção e quantificação automática da cercosporiose em condições de campo. A comparação sistemática entre essas duas arquiteturas distintas revelou que modelos baseados em Mask R-CNN apresentam melhor desempenho em métricas em nível de pixel, enquanto modelos YOLOv8 demonstram superioridade na classificação dos níveis de severidade, fornecendo insights valiosos sobre as características e aplicabilidades de cada arquitetura para diferentes tarefas de diagnóstico fitossanitário. A criação e disponibilização pública de um conjunto de dados contendo 1.645 imagens e 6.282 lesões de cercosporiose em pimenta malagueta representa uma contribuição para a comunidade científica, fornecendo recurso para o desenvolvimento e validação de novos modelos de aprendizado profundo aplicados ao diagnóstico fitossanitário desta cultura. A integração dessas tecnologias em um sistema de apoio à decisão móvel, denominado FitoView, permitiu combinar análise de imagens por redes neurais convolucionais com dados de previsão meteorológica em tempo real, oferecendo aos agricultores recomendações contextualizadas de manejo.

A natureza interdisciplinar deste trabalho, integrando conhecimentos de fitopatologia, visão computacional, inteligência artificial, meteorologia e ciências sociais aplicadas à agricultura, representa uma contribuição metodológica ao demonstrar a necessidade de abordagens integradas para enfrentamento de desafios complexos da agricultura contemporânea.

Os resultados obtidos confirmam a hipótese central de que a detecção e avaliação automática da severidade da cercosporiose, quando associadas a informações de previsão climática e integradas em sistemas de apoio à decisão acessíveis, podem efetivamente aumentar a eficiência no controle da doença e fornecer subsídios relevantes aos pequenos agricultores, favorecendo práticas de manejo mais sustentáveis que reduzam a dependência

de defensivos químicos.

As implicações práticas deste trabalho estendem-se para além do contexto específico estudado, oferecendo um framework metodológico e tecnológico que pode ser adaptado para outras culturas e patossistemas, especialmente em contextos de agricultura familiar onde limitações de recursos e conhecimento técnico especializado representam barreiras significativas.

As limitações identificadas, incluindo desafios de conectividade em áreas rurais, necessidades de capacitação digital e questões de acessibilidade econômica, apontam para a necessidade de políticas públicas que apoiem a infraestrutura digital rural e promovam processos inclusivos de inovação tecnológica na agricultura. Trabalhos futuros devem focar em estudos longitudinais que acompanhem processos de adoção em longo prazo, avaliação quantitativa do impacto econômico e ambiental das tecnologias implementadas, desenvolvimento de metodologias participativas de co-design, e expansão das aplicações para outros cultivos e regiões.

Em síntese, esta tese demonstra que a integração entre inteligência artificial, dados meteorológicos e abordagens participativas de implementação tecnológica pode contribuir efetivamente para uma agricultura mais sustentável, precisa e acessível, especialmente quando desenvolvida considerando as realidades, necessidades e potencialidades da agricultura familiar brasileira.

9 Anexos

9.1 Laudo de Diagnóstico Fitossanitário

Este anexo apresenta o laudo técnico emitido pela Companhia de Desenvolvimento Regional de Sergipe (CODERSE), Departamento de Assistência Técnica e Extensão Rural, atestando a identificação da cercosporiose (*Cercospora capsici*) nas amostras coletadas em campo no Município de Lagarto, Estado de Sergipe, durante o desenvolvimento desta pesquisa.



COMPANHIA DE DESENVOLVIMENTO REGIONAL DE SERGIPE – CODERSE
Departamento de Assistência Técnica e Extensão Rural

LAUDO DE DIAGNÓSTICO FITOSSANITÁRIO

1. Identificação da Amostra

Cultura: Pimenta (*Capsicum* spp.).

Localização da Coleta: Município de Lagarto, Estado de Sergipe, Brasil.

Coordenadas Geográficas: Lat: -10.9145, Long: -37.6639.

Responsável pela Coleta: Douglas Vieira Leite.

Método de Análise: Diagnose visual e análise de caracteres patognomônicos em campo.

2. Descrição Sintomatológica

As amostras analisadas apresentam sintomas típicos de infecção por *Cercospora capsici*. As lesões foliares observadas no campo são caracterizadas por manchas circulares com centros necróticos de coloração acinzentada e bordos marrom-escuros bem definidos.

É evidente a presença de um halo clorótico (amarelamento) circundando as lesões, sintoma clássico da dispersão da toxina cercosporina no tecido foliar. Em estágios avançados, observa-se a coalescência das manchas, resultando em senescência prematura e queda das folhas afetadas.


3. Documentação Fotográfica



Figura 1: Registro fotográfico das amostras de folhas de pimenta coletadas em campo, evidenciando lesões necróticas circulares com halo clorótico características de *Cercospora capsici*.

4. Parecer Técnico

Com base na análise das evidências fotográficas e na morfologia das lesões observadas *in loco*, este departamento ratifica o diagnóstico de **Cercosporiose da Pimenta**. Os sintomas apresentados são específicos e suficientes para a identificação do gênero *Cercospora* na cultura em questão.


Marcos Emílio Almeida
Técnico Agrícola
CODERSE – Sergipe