



INSTITUTO FEDERAL GOIANO
CAMPUS URUTAÍ
NÚCLEO DE INFORMÁTICA
CURSO DE SISTEMAS DE INFORMAÇÃO

WALMIR CARDOSO DOS SANTOS ROSA

CLASSIFICAÇÃO DE DANOS FOLIARES USANDO DEEP LEARNING

Urutaí, 3 de março de 2026

INSTITUTO FEDERAL GOIANO

NÚCLEO DE INFORMÁTICA

SISTEMAS DE INFORMAÇÃO

WALMIR CARDOSO DOS SANTOS ROSA

CLASSIFICAÇÃO DE DANOS FOLIARES USANDO DEEP LEARNING

Trabalho de Conclusão de Curso apresentado ao Núcleo de Informática, curso de Sistemas de Informação, do Instituto Federal Goiano, como parte das exigências para obtenção do título de Bacharel em Sistemas de Informação.

Orientador(a):
Gabriel da Silva Vieira

Urutaí, 3 de março de 2026

**Ficha de identificação da obra elaborada pelo autor, através do
Programa de Geração Automática do Sistema Integrado de Bibliotecas do IF Goiano - SIBi**

C268 Cardoso dos Santos Rosa, Walmir
 CLASSIFICAÇÃO DE DANOS FOLIARES USANDO DEEP
 LEARNING / Walmir Cardoso dos Santos Rosa. Urutai 2026.

1f. il.

Orientador: Prof. Dr. Gabriel Vieira.

Tcc (Bacharel) - Instituto Federal Goiano, curso de 0120201 -
Bacharelado em Sistemas de Informação - Urutai (Campus
Urutai).

I. Título.

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO

PARA DISPONIBILIZAR PRODUÇÕES TÉCNICO-CIENTÍFICAS

NO REPOSITÓRIO INSTITUCIONAL DO IF GOIANO

Com base no disposto na Lei Federal nº 9.610, de 19 de fevereiro de 1998, AUTORIZO o Instituto Federal de Educação, Ciência e Tecnologia Goiano a disponibilizar gratuitamente o documento em formato digital no Repositório Institucional do IF Goiano (RIIF Goiano), sem ressarcimento de direitos autorais, conforme permissão assinada abaixo, para fins de leitura, download e impressão, a título de divulgação da produção técnico-científica no IF Goiano.

IDENTIFICAÇÃO DA PRODUÇÃO TÉCNICO-CIENTÍFICA

- ☐ Tese (doutorado)
☐ Dissertação (mestrado)
☐ Monografia (especialização)
☒ TCC (graduação)

- ☐ Artigo científico
☐ Capítulo de livro
☐ Livro
☐ Trabalho apresentado em evento

☐ Produto técnico e educacional - Tipo:

Nome completo do autor:

Walmir Cardoso do Santos Rosa

Matrícula:

2022101202010180

Título do trabalho:

CLASSIFICAÇÃO DE DANOS FOLIARES
USANDO DEEP LEARNING

RESTRIÇÕES DE ACESSO AO DOCUMENTO

Documento confidencial: ☒ Não ☐ Sim, justifique:

Informe a data que poderá ser disponibilizado no RIIF Goiano: 02/03/2026

O documento está sujeito a registro de patente? ☐ Sim ☒ Não

O documento pode vir a ser publicado como livro? ☐ Sim ☒ Não

DECLARAÇÃO DE DISTRIBUIÇÃO NÃO-EXCLUSIVA

O(a) referido(a) autor(a) declara:

- Que o documento é seu trabalho original, detém os direitos autorais da produção técnico-científica e não infringe os direitos de qualquer outra pessoa ou entidade;
- Que obteve autorização de quaisquer materiais inclusos no documento do qual não detém os direitos de autoria, para conceder ao Instituto Federal de Educação, Ciência e Tecnologia Goiano os direitos requeridos e que este material cujos direitos autorais são de terceiros, estão claramente identificados e reconhecidos no texto ou conteúdo do documento entregue;
- Que cumpriu quaisquer obrigações exigidas por contrato ou acordo, caso o documento entregue seja baseado em trabalho financiado ou apoiado por outra instituição que não o Instituto Federal de Educação, Ciência e Tecnologia Goiano.

Documento assinado digitalmente
 **WALMIR CARDOSO DOS SANTOS ROSA**
Data: 28/02/2026 11:24:57-0300
Verifique em <https://validar.iti.gov.br>

Urutai

Local

28/02/2026

Data

Assinatura do autor e/ou detentor dos direitos autorais

Ciente e de acordo:

Assinatura do(a) orientador(a)



SERVIÇO PÚBLICO FEDERAL
MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA GOIANO

Documentos 2/2026 - CCBSI-URT/GE-UR/DE-UR/CMPURT/IFGOIANO

WALMIR CARDOSO DOS SANTOS

CLASSIFICAÇÃO DE DANOS FOLIARES USANDO DEEP LEARNING

Monografia, defendida por Walmir Cardoso dos Santos, apresentada ao Instituto Federal de Educação, Ciência e Tecnologia Goiano, como parte das exigências para a obtenção do título de Bacharel em Sistemas de Informação, aprovada pela banca examinadora.

COMISSÃO EXAMINADORA

(Assinado Eletronicamente)

Prof. Dr. Gabriel da Silva Vieira

Orientador

(Assinado Eletronicamente)

Prof. Dr. Junio Cesar de Lima

Avaliador

(Assinado Eletronicamente)

Prof. Me. Amaury Walbert de Carvalho

Avaliador

Urutaí (GO), 19 de fevereiro de 2026.

Documento assinado eletronicamente por:

- **Gabriel da Silva Vieira, PROFESSOR ENS BASICO TECN TECNOLOGICO** , em 19/02/2026 15:47:31.
- **Amaury Walbert de Carvalho, PROFESSOR ENS BASICO TECN TECNOLOGICO** , em 19/02/2026 15:48:47.
- **Junio Cesar de Lima, PROFESSOR ENS BASICO TECN TECNOLOGICO** , em 19/02/2026 15:49:45.

Este documento foi emitido pelo SUAP em 17/02/2026. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifgoiano.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código Verificador: 789605

Código de Autenticação: 30bc098604



INSTITUTO FEDERAL GOIANO

Campus Urutaí

Rodovia Geraldo Silva Nascimento, Km 2.5, SN, Zona Rural, URUTAÍ / GO, CEP 75790-000

(64) 3465-1900

Dedico este trabalho aos meus familiares e professores.

AGRADECIMENTOS

Agradeço, primeiramente, a Deus, por permitir que as pessoas certas entrassem em minha vida, tornando possível vivenciar tudo o que aconteceu ao longo dessa trajetória. Tenho eterna gratidão à minha mãe, Altina dos Santos, que sempre acreditou em mim e me apoiou nos momentos em que pensei em desistir. Agradeço também a Samuel Alves, que me indicou esta faculdade e este lugar. Essas duas pessoas foram fundamentais para que eu me reencontrasse quando me sentia perdido. Sou igualmente grato ao meu pai, Salviano Cardoso, e à minha avó, Teodora. Embora infelizmente não estejam mais entre nós, sei que sem eles nada disso teria sido possível. Estendo meus agradecimentos aos meus irmãos e a toda a minha família, pelo apoio e incentivo constantes.

Expresso minha sincera gratidão ao Campus Urutaí, onde recebi moradia e incentivo para continuar nessa caminhada acadêmica.

Agradeço também à cidade de Urutaí e a cada colega e amigo que cruzou meu caminho. Foram muitos momentos de felicidade e também de dificuldades compartilhadas. Cheguei sozinho, mas, ao longo desses quatro anos, cada pessoa ocupou um lugar especial em meu coração e em minha vida. Independentemente de onde eu esteja, levarei comigo tudo o que aprendi com cada um.

Com carinho, agradeço aos meus professores, em especial a Junio e Deydson, pelo incentivo constante, pelo apoio, pela paciência, pelas conversas, pelas brincadeiras e por todo o conhecimento compartilhado. Mais do que profissionais, foram amigos que ouviram nossas histórias e nos compreenderam. Graças ao que aprendi com vocês, conquistei meu primeiro estágio e minha efetivação, atuando hoje como desenvolvedor backend. Meu muito obrigado.

Aos meus amigos João Vitor, Clarice, Isaías, Ariane, Ariana, Marlon, Jhennyf e João Vitor Paganí, sou profundamente grato pelas conversas, pelas ajudas, por cada momento vivido e por estarem ao meu lado neste capítulo tão importante da minha vida.

Agradeço ao meu orientador, Gabriel da Silva Vieira, por toda a paciência, apoio e, principalmente, por sempre exigir mais de mim, mostrando que eu era capaz de realizar desafios que antes pareciam impossíveis. Levarei comigo o carinho e a admiração por você. Muito obrigado, professor.

Por fim, deixo um agradecimento especial à minha irmã Iza e à minha afilhada e sobrinha Ana Liz, que me deram a força necessária para me tornar uma pessoa melhor e me incentivaram nesta reta final de mais uma etapa da minha vida.

A todos que fizeram parte dessa jornada, deixo meu mais profundo e sincero agradecimento. Este trabalho é fruto não apenas do meu esforço, mas também do apoio e da confiança de cada pessoa que acreditou em mim ao longo da minha formação.

A soja, uma fonte essencial de proteína para a alimentação humana e animal, é especialmente vulnerável a ataques de insetos desfolhadores. A coleta e identificação de forma manual de insetos presentes nas lavouras é uma prática demorada e suscetível a erros. Considerando o impacto positivo de técnicas de monitoramento em campos de cultivos, o uso de dispositivos móveis juntamente com ferramentas de visão computacional vem ganhando destaque na agricultura de precisão.

Diferente de outros estudos que se concentram unicamente no desenvolvimento de modelos para detecção de pragas ou doenças, este trabalho propõe uma abordagem baseada na classificação indireta de insetos por meio dos danos foliares, além da integração do modelo a uma aplicação móvel como prova de conceito, demonstrando sua viabilidade prática.

Comparamos três arquiteturas de redes neurais, ResNet50, VGG16, e InceptionV3, para classificar duas pragas da soja (vaquinha verde e lagarta-da-soja). As três arquiteturas apresentaram ótimo desempenho na classificação com acurácia acima dos 90%, mas a VGG16 apresentou o melhor desempenho, com 95.75%. Os resultados demonstram a capacidade dos modelos de aprendizado profundo para o reconhecimento de insetos com base nos danos que eles causam às folhas e evidenciam o potencial da integração entre os modelos de deep learning e aplicações móveis, fornecendo assim uma alternativa viável para o monitoramento de pragas no cultivos da soja.

Palavras-chave:

Aprendizado Profundo; Redes Neurais Convolucionais; Agricultura de Precisão; Agricultura Inteligente; Classificação de Pragas.

LISTA DE FIGURAS

4.1	Amostra do banco dados com danos construídos artificialmente.	29
4.2	Fluxograma do processo metodológico adotado	29
4.3	Configurações do <i>Google Colab</i>	31
5.1	Matrizes confusão com a predição e os resultados usando VGG16, ResNet50 e InceptionV3.	35
5.2	Curvas ROC usando arquiteturas VGG16, ResNet50 e InceptionV3.	37
5.3	Mapas de ativação das camadas convolucionais VGG16 usando Grad-CAM. . .	38

LISTA DE ABREVIATURAS E SIGLAS

CNN	Rede Neural Convolucional
DL	<i>Deep Learning</i>
FAO	<i>Food and Agriculture Organization</i>
FN	Falso Negativo
FP	Falso Positivo
GPU	Graphics Processing Unit
GRAD-CAM	<i>Gradient-weighted Class Activation Mapping</i>
IA	Inteligência Artificial
IEEE	Instituto de Engenheiros Eletricistas e Eletrônicos
ML	<i>Machine Learning</i>
reLU	Unidade Linear Retificada
ResNet	<i>Residual Neural Network</i>
RGB	<i>Red, Green, Blue</i>
VGG	<i>Visual Geometry Group</i>
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo

1	INTRODUÇÃO	12
1.1	Contextualização	14
1.2	Justificativa	15
1.3	Objetivos	16
1.3.1	Objetivo Geral	16
1.3.2	Objetivos Específicos	16
1.4	Metodologia	16
2	TRABALHOS RELACIONADOS	18
3	MATERIAIS	21
3.1	Base de Dados de Folha	21
3.2	Base de Dados com Danos Foliares	21
3.3	Aprendizado Profundo	22
3.4	Redes Neurais Convolucionais	23
3.4.1	VGG - Visual Geometry Group	23
3.4.2	ResNet - Residual Neural Network	24
3.4.3	Inception	24
3.5	Métricas de Avaliação	24
3.5.1	Matriz Confusão	25
3.5.2	Precisão	25
3.5.3	Recall	25
3.5.4	F1-Score	25
3.5.5	Acurácia	26
3.5.6	Curvas ROC	26
3.5.7	Grad-CAM	26
4	Métodos	27
4.1	Construção do Dataset e Estratégia de Treinamento	27
4.1.1	Seleção e Segmentação dos Danos Foliares	27
4.1.2	Simulação de Danos Foliares	28
4.1.3	Transferência de Aprendizado	28
4.2	Organização do Experimento	30
4.2.1	Separação dos Dados	30

4.3	Preparação dos Modelos	31
4.4	Construção dos Modelos	31
4.4.1	Coleta de Dados	32
4.4.2	Avaliação dos Resultados	32
5	RESULTADOS E DISCUSSÃO	33
	CONCLUSÃO	41
5.1	Trabalhos Futuros	41

CAPÍTULO 1

INTRODUÇÃO

Todos os anos, pequenos e grandes produtores agrícolas sofrem com os impactos de pragas em suas lavouras, destacando-se a predação foliar causada por insetos mastigadores e sugadores. A remoção de área foliar compromete processos fisiológicos essenciais ao desenvolvimento vegetal, podendo refletir negativamente no rendimento das culturas

Segundo Levin (2017), a perda anual brasileira decorrente do ataque de insetos nas lavouras é estimada em aproximadamente 7,7%, valor correspondente a quase 25 milhões de toneladas de produtos agrícolas, com prejuízos econômicos da ordem de 17,7 bilhões de dólares. Esses dados evidenciam a magnitude do impacto das pragas agrícolas na produção nacional.

A perda de produtos agrícolas decorre da proliferação descontrolada de pragas que levam a má formação frutífera, a redução do volume de grãos, o envelhecimento precoce dos cultivos, e ao abandono prematuro ou descontinuidade de lavouras. Em ecossistemas balanceados a coexistência de insetos em lavouras é salutar, significando que existe equilíbrio e troca de benefícios entre eles. Alguns insetos podem inibir o surgimento de pragas agressivas e prejudiciais ao plantio, enquanto os insumos providenciados pelas lavouras servem de alimento para manter a subsistência de diferentes espécies. O problema surge quando evidencia-se desequilíbrio ambiental com prejuízos às expectativas de produção.

Nesses casos, a precisão nas informações é crucial para que a tomada de decisão seja adequada ao problema atual, iminente, ou futuro. Informações com alto grau de assertividade corroboram para fundamentar escolhas de manejo agrícola por meio do combate biológico, uso de inseticidas, aplicação de defensivos agrícolas, adubação, e abordagens de contenção.

Para monitorar a flutuação populacional de insetos utiliza-se, predominantemente, arma-

dilhas. Este recurso é amplamente utilizado e permite a captura de insetos para investigação. Contudo, como apontado por Domênico et al. (2021), a tarefa de identificação manual de insetos como parasitoides (Hymenoptera: Aphelinidae e Braconidae, Aphidiinae) desenvolvida por rede de monitoramento é demorada, fatigante e não escalável.

De acordo com Júnior e Rieder (2020) no que se refere às armadilhas em lavouras, esse processo pode ser mais trabalhoso quando comparado às armadilhas de laboratório, uma vez que o ambiente externo geralmente é afetado por muitos fatores ambientais e contém outros vestígios, como detritos, lama, folhas, materiais naturais soltos e outros insetos que precisam ser previamente identificados e removidos. Alguns outros fatores que dificultam a identificação desses insetos de forma manual é a (i) decomposição do inseto e perda de membros, ou a (ii) descoloração de insetos por reação com solução de sabão ou álcool em armadilhas de bandeja.

Com o rápido desenvolvimento das redes neurais convolucionais, pesquisadores começaram a utilizá-las para desenvolver sistemas de classificação de imagens para identificar pragas e doenças, como o Bijlwan et al. (2025) que utilizou modelos de deep learning para identificação de pragas e doenças no cultivo do arroz.

Embora os sistemas de detecção permitam identificar a presença de pragas nas plantações, é difícil inferir a partir deles a linha que cruza a normalidade populacional e o surto de uma determinada espécie. Entre os fatores que limitam essas soluções, destaca-se a mobilidade dos insetos entre as plantas, pois conforme eles se movem, pode haver registros diferentes para o mesmo espécime em diferentes plantas, e os sistemas de visão podem não conseguir registrar a presença de insetos quando eles se movem rapidamente ou estão camuflados, escondidos, ou em grupos. Por outro lado, os danos causados por insetos limitam-se à localização das plantas injuriadas, que podem ser utilizadas para direcionar análises foliares e verificar a sanidade local e global das lavouras, mesmo na ausência do inseto causador das perdas. A partir daí, podem ser feitas inferências sobre o equilíbrio ecológico.

Portanto neste trabalho investigamos uma abordagem diferente das classificações comuns, ao invés de captura e identifica os insetos de forma manual, utilizamos as marcas deixadas pelas pragas nas folhas como característica distintiva para sua classificação. Essa abordagem dispõe de diversas vantagens como a redução do tempo e do custo de monitoramento e a possibilidade de detectar pragas em estágios iniciais. Foram feitas as implementações das redes neurais convolucionais VGG-16, ResNet-50 e Inception-V3, a fim de comparar qual delas apresenta um desempenho melhor na classificação de danos foliares na cultura da soja.

Para avaliar a viabilidade dessa abordagem, desenvolvemos um conjunto de dados contendo imagens de folhas de soja com danos simulados causados por duas das principais pragas da soja: *Diabrotica speciosa* (Coleoptera: Chrysomelidae – vaquinha verde) e *Anticarsia gemmatilis* (Insect: Lepidoptera: Noctuidae – lagarta-da-soja). Em seguida avaliamos três arquiteturas de redes neurais convolucionais (CNNs) para a classificação dos danos foliares associados às pragas. Os resultados foram promissores tendo os três modelos escolhidos apresentado acurácia acima dos 90%.

1.1 Contextualização

Com o crescimento acelerado da população mundial e as mudanças demográficas observadas nas últimas décadas, os sistemas agrícolas enfrentam o desafio de ampliar a produção de alimentos de forma sustentável. Embora a Revolução Verde tenha proporcionado avanços significativos na produtividade agrícola ao longo do século XX, parte desses ganhos foi comprometida por políticas inadequadas de intervenção e pela persistência de desigualdades socioeconômicas (BORLAUG, 2017). Isso não significa, contudo, que o potencial de incremento produtivo tenha se esgotado.

Aumentos na produtividade ainda podem ser alcançados em diferentes etapas do sistema agrícola, incluindo o manejo das culturas, o uso eficiente da água, a fertilização, o controle de plantas daninhas e pragas, bem como nos processos de colheita. Entretanto, para que o melhoramento genético das culturas alimentares continue em ritmo compatível com as demandas populacionais — estimadas em 8,3 bilhões de pessoas até 2025 — serão necessárias abordagens integradas que envolvam tanto metodologias convencionais quanto biotecnológicas (BORLAUG, 2017).

Nesse contexto, destaca-se também a necessidade de uma “Revolução Azul”, voltada à ampliação da produtividade do uso da água em consonância com a produtividade do uso da terra, especialmente diante das limitações hídricas previstas para o século XXI. Assim, novas ciências e tecnologias tornam-se fundamentais para sustentar o crescimento da produção agrícola de maneira eficiente e ambientalmente responsável (BORLAUG, 2017).

Diante desse cenário, torna-se imprescindível o desenvolvimento de estratégias que contribuam para a redução de perdas ao longo do processo produtivo agrícola. Entre os fatores que impactam negativamente a produtividade, destacam-se os danos causados por pragas, cuja identificação e manejo adequados são essenciais para a manutenção da eficiência produtiva,

especialmente em culturas de elevada relevância econômica, como a soja.

1.2 Justificativa

A sociedade humana precisa aumentar a produção de alimentos em cerca de 70% até 2050 para alimentar uma população estimada em mais de 9 bilhões de pessoas (BORLAUG, 2017). Diante desse cenário, torna-se fundamental não apenas ampliar áreas de cultivo, mas também aumentar a eficiência produtiva, reduzindo perdas ao longo do processo agrícola.

Dentre os fatores que impactam negativamente a produção das lavouras, ressaltam-se os ataques de insetos desfoliadores. A desfolha decorrente de ataques de insetos pode reduzir a transpiração, a fotossíntese e a capacidade das plantas de compensar deficiências nutricionais, perda de água e outros fatores abióticos que podem influenciar a produção vegetal (OWEN et al., 2013). Logo ocorre diminuição tanto na qualidade quanto na quantidade da produção agrícola. Portanto, pode-se inferir que, é de suma importância mitigar perdas nas plantações causadas por insetos desfoliadores.

Nesse contexto, a integração entre agricultura e tecnologia surge como um caminho promissor. O avanço da inteligência artificial tem possibilitado o desenvolvimento de ferramentas capazes de auxiliar na análise de dados agrícolas, especialmente por meio do processamento de imagens. Entre essas técnicas, destacam-se as Redes Neurais Convolucionais (CNNs), amplamente utilizadas em tarefas de classificação e detecção de padrões visuais. Essas redes são treinadas a partir de grandes volumes de dados e demandam considerável capacidade computacional; contudo, a redução nos custos de hardware tem ampliado sua viabilidade de aplicação em diversas áreas, incluindo o campo agrícola.

Dessa forma, este trabalho propõe a classificação de pragas com base nos danos causados na cultura da soja, considerando dois tipos principais: o besouro conhecido como vaquinha-verde e a lagarta-da-soja. A partir da análise de imagens dos danos foliares, busca-se verificar a viabilidade do uso de CNNs como ferramenta de apoio na identificação dessas pragas. Ao compartilhar os resultados obtidos, pretende-se contribuir para o fortalecimento das pesquisas que integram agricultura e tecnologia, oferecendo mais uma aplicação prática da inteligência artificial no contexto da produção agrícola.

Neste sentido, apresentamos na Seção 2 trabalhos relacionados a este estudo. Nas Seções 3 e 4.1, apresentamos os materiais e métodos necessários para reproduzir a pesquisa. Na Seção 4.2 apresentamos detalhes sobre a organização e execução dos experimentos. Na Seção 5,

apresentamos resultados e discussão considerando a assertividade dos três modelos investigados. Por último, o trabalho é concluído na Seção 5.

1.3 Objetivos

1.3.1 Objetivo Geral

Elaborar uma solução computacional para a classificação de danos foliares causados por pragas na cultura da soja.

1.3.2 Objetivos Específicos

1. Reproduzir danos de insetos em folhas e construir uma base de dados com imagens para uso no treinamento, validação, e teste de redes neurais artificiais.
2. Implementar arquiteturas de redes neurais convolucionais em *Python* utilizando o conjunto de dados desenvolvido por (HUGHES et al., 2015a) e adaptado pelos autores para o treinamento de modelos computacionais.
3. Simular e preparar a extração dos danos causados por lesmas e lagartas utilizando *Matlab*.
4. Comparar os modelos de aprendizagem profunda VGG-16, InceptionV3 e ResNet-50 na classificação de classes de interesse.
5. Desenvolver uma interface de serviço (API) para disponibilizar o modelo treinado e realizar o processo de inferência.
6. Implementar uma aplicação móvel simples como prova de conceito para consumo da API, demonstrando a aplicabilidade prática do modelo proposto.

1.4 Metodologia

A realização deste trabalho de final de curso foi organizada em 4 fases: Estudo Teórico e Prático, Fundamentação Teórica, Execução do Trabalho, Implementação e Análise.

1. Iniciamos o trabalho a partir de estudos teóricos e prático acerca de métodos computacionais, incluindo conceitos como: *deep learning*, métricas de sucesso e desenvolvimento de códigos oriundos do *github*.

2. Posteriormente, foram realizadas buscas por projetos similares e relevantes, por meio das seguintes palavras-chave: "*detection*", "*defoliation*" e "*deep learning*", "*insect*" além de outros termos identificados que filtraram os resultados necessários para a fundamentação teórica desse trabalho.
3. Preparamos o conjunto de dados com as classes de interesse e implementamos modelos de redes neurais convolucionais na linguagem *Python* a fim de analisar a assertividade na classificação das pragas responsáveis pela desfolha.
4. Com base nos resultados das implementações das arquiteturas VGG-16, ResNet-50 e InceptionV3, foram realizadas comparações e análises. A partir disso, discutimos esses *insights* na forma de monografia.

CAPÍTULO 2

TRABALHOS RELACIONADOS

A seguir são apresentados os principais trabalhos relacionados.

No contexto da classificação de imagens, o cérebro humano faz essa tarefa intuitivamente e sem esforço algum. No âmbito da visão computacional, é necessário a extração de padrões e características, para isso é utilizando o aprendizado profundo.

Na conjuntura da visão computacional, é possível identificar pessoas, assinaturas de usuários, e objetos. No reconhecimento de imagens, os computadores utilizam algoritmos de visão computacional e modelos de redes neurais artificiais que são capazes de analisar e extrair características relevantes de imagens para identificar objetos.

Na esteira do desenvolvimento das novas tecnologias de vanguarda e popularização da inteligência artificial, inúmeros estudos têm emergido propondo modelos computacionais para otimizar demandas provenientes de ambientes rurais. Ferramentas computacionais têm sido desenvolvidas para lidar com a estimativa de perda foliar (VIEIRA et al., 2022; GOSHIKA et al., 2024; VIEIRA et al., 2023), segmentação de árvores (VIEIRA et al., 2019a; VIEIRA et al., 2019b; LI et al., 2023), detecção de predação de insetos (VIEIRA et al., 2022), reconstrução foliar (VIEIRA et al., 2021), reconhecimento de pragas (FU et al., 2023), modelagem de insetos em 3D (DOAN; NGUYEN, 2023), identificação de danos em frutos (ZHANG et al., 2022; FENG et al., 2023), monitoramento de culturas (RUSTIA et al., 2023; CHEN et al., 2024) e classificação de insetos (YANG et al., 2023). Essas iniciativas de pesquisa têm trazido resultados promissores para a inserção de novas tecnologias nas fazendas. Uma contribuição que se destaca é ajuda dada ao produtor rural na tomada de decisão por meio da apresentação de informações altamente precisas.

Segundo Júnior et al. (2020), a identificação de insetos em imagem apresenta grandes

desafios uma vez que imagens digitais contendo objetos capturados em campo apresentam conexões ou sobreposições parciais e/ou totais entre os insetos de interesse. Apesar disso, o uso da aprendizagem de máquina no âmbito da agricultura vem reduzindo tempo e custos em tarefas repetitivas, como a identificação e contagem de objetos em imagens digitais.

Dessa forma, vários estudos afirmam que modelos computacionais se sobressaem em relação ao processo manual de identificação de insetos que costuma ser lento, tedioso, suscetível a erros, e de baixa precisão, impedindo a execução em larga escala (JÚNIOR; RIEDER, 2020)

Garcia e Perico (2018) propuseram um modelo de aprendizagem para diferenciar percevejos-marrom fêmeas de macho. Redes neurais convolucionais foram investigadas nesse estudo obtendo acurácia de 78%. De acordo com o autor, mudanças do modelo da rede neural convolucional poderiam suscitar melhores resultados, pois após mil episódios de treinamento, o aprendizado estagnou.

Avila-George et al. (2018) utilizou do aprendizado de máquina para detectar danos em folhas de tabaco causadas pelo mofo azul. Utilizando redes neurais, uma aplicação para dispositivos móveis foi desenvolvida no qual a experimentação realizada mostrou que o modelo desenvolvido atingiu precisão superior a 97%. Segundo o autor, esse estudo foi pioneiro na identificação de doenças e pragas, pois foi o primeiro a reconhecer os danos deixados em folhas na cultura do tabaco.

Vieira et al. (2024) apresentaram um novo método para examinar o estresse foliar causado pela herbivoria de insetos através de uma abordagem abrangente para inspeções visuais de danos foliares. O método dos autores contou com análise foliar com etapas de processamento bem definidas para calcular a gravidade da predação de insetos nas folhas. Resultados experimentais mostraram alta assertividade na estimativa da perda de área foliar com coeficiente de correlação de concordância de 0.98 para folhas de uva, soja, batata e morango.

Vieira et al. (2022) desenvolveu um método para detectar predação de insetos em folhas de plantas que usa propriedades geométricas das folhas e técnicas de processamento de imagens digitais para construir modelos de imagens. Além disso, o método proposto pelos autores identifica áreas de predação de insetos, independentemente da espécie de planta, mas com alta precisão em folhas de mirtilo, milho, batata e soja.

Nessa linha de investigação, Zhu et al. (2024) apresentou um modelo de rede neural capaz de distinguir dois tipos de insetos desfoliadores de soja a partir dos danos foliares. Como os autores, também acreditamos que estudos desse tipo fornecem apoio valioso para monitoramento

e controle de pragas por trabalhadores agrícolas.

Nessa mesma linha de investigação, Mignoni et al. (2025) investigaram a identificação de pragas da soja a partir da análise de danos foliares utilizando redes neurais convolucionais. Diferentemente de abordagens baseadas na identificação direta do inseto, os autores exploraram a desfolha como um proxy visual para inferir a presença da praga, utilizando imagens reais capturadas por veículos aéreos não tripulados (UAV) em ambiente agrícola. Tal estratégia introduz desafios adicionais, como variações de iluminação, complexidade de fundo e sobreposição de danos, características inerentes ao cenário de campo.

Os resultados apresentados por aqueles autores indicaram maior facilidade na classificação da classe folha saudável e maior dificuldade na distinção de classes, destacando a vaquinha verde. Esses achados evidenciam que a similaridade morfológica entre lesões constitui um desafio intrínseco à tarefa de classificação.

O presente estudo posiciona-se nesse contexto ao propor a classificação de insetos desfoliadores da soja a partir dos danos foliares. Entretanto, diferencia-se ao empregar danos sintéticos aplicados sobre folhas saudáveis, permitindo controle sobre a morfologia das lesões e a redução de variáveis externas, como iluminação e ruído de fundo. Além disso, realiza-se a comparação entre múltiplas arquiteturas de redes neurais profundas, com o objetivo de analisar o poder discriminativo dos padrões de dano de forma mais isolada. Dessa maneira, esta pesquisa contribui para a compreensão do potencial e das limitações da inferência indireta baseada em danos foliares, complementando investigações conduzidas em cenários reais de campo.

CAPÍTULO 3

MATERIAIS

Neste capítulo são apresentados os materiais utilizados na pesquisa, incluindo as bases de dados empregadas, as arquiteturas de redes neurais convolucionais investigadas e as métricas de avaliação utilizadas para análise dos experimentos.

3.1 Base de Dados de Folha

Para a construção de base de dados com imagens de folha com danos foliares sintéticos, inicialmente, utilizamos uma base de dados pública preparadas por (HUGHES et al., 2015b). No preparo dessa base de dados os autores disponibilizaram 50.000 imagens de folhas saudáveis e folhas agravadas por doenças de várias espécies vegetais como soja, milho, mirtilo entre outras. A coleção apresenta diversas condições de iluminação, ângulo, e modelo foliar, proporcionando uma base de dados diversificada.

Dessa coleção de dados, foram selecionadas apenas folhas saudáveis da soja, usadas em um processo para aplicar danos foliares sintéticos (Seção 4.1).

3.2 Base de Dados com Danos Foliares

Neste trabalho utilizamos um conjunto de dados de folhas de soja danificadas por insetos preparado por Mignoni et al. (MIGNONI et al., 2022). Nessa base, a captura de imagens foi realizada em diversas fazendas de soja, sob condições climáticas realistas, usando dois celulares e um veículo aéreo não-tripulado. O conjunto de dados consiste em três pastas com um total de 6.410 imagens. O conjunto de dados é dividido em três categorias: (I) plantas saudáveis, (II) plantas afetadas por lagartas e (III) imagens de plantas danificadas por *Diabrotica speciosa*.

Embora esse conjunto de dados apresente folhas em condições reais de campo, suas imagens frequentemente apresentam múltiplas folhas na mesma cena, imagens repetidas, variações de iluminação, sombras e danos que não constituem o foco central da imagem. Essas características dificultam o uso direto do *dataset* para o treinamento de modelos cujo objetivo é analisar exclusivamente os padrões dos danos foliares, uma vez que o modelo pode aprender informações relacionadas ao contexto da cena, e não apenas às marcas deixadas pelos insetos.

Dessa forma, optou-se por utilizar esse conjunto de dados como fonte para a extração de padrões reais de danos foliares, seguido por um programa elaborado pelos autores para simular condições reais do no campo. Esses danos foram extraídos manualmente e posteriormente aplicados de forma automática sobre imagens de folhas saudáveis, por meio de um algoritmo (Seção 4.1), permitindo maior controle experimental e a avaliação da viabilidade de diferenciar classes de insetos com base exclusivamente nas marcas deixadas nas folhas.

3.3 Aprendizado Profundo

O Aprendizado Profundo (*Deep Learning* – DL) constitui uma subárea do Aprendizado de Máquina (*Machine Learning* – ML) caracterizada pelo uso de modelos baseados em múltiplas camadas de redes neurais artificiais. Diferentemente de abordagens tradicionais de ML, que frequentemente dependem de engenharia manual de atributos (*feature engineering*), o DL é capaz de aprender representações hierárquicas diretamente a partir dos dados brutos, reduzindo a necessidade de intervenção humana na etapa de extração de características (CHOWANDA; CHOWANDA, 2017).

Entre as arquiteturas mais empregadas em tarefas de visão computacional destacam-se as Redes Neurais Convolucionais (*Convolutional Neural Networks* – CNNs). Essas redes são especialmente projetadas para processar dados estruturados em grade, como imagens, explorando relações espaciais entre pixels. Uma CNN é composta, tipicamente, por camadas convolucionais, camadas de ativação não linear, camadas de *pooling* e, ao final, camadas totalmente conectadas responsáveis pela etapa de classificação.

Considerando uma imagem de entrada representada por três dimensões — altura, largura e número de canais (por exemplo, RGB) —, a operação de convolução consiste na aplicação de filtros (ou *kernels*) que percorrem a imagem extraíndo padrões locais. Cada filtro realiza operações matemáticas sobre regiões específicas da imagem, produzindo mapas de características (*feature maps*) que destacam estruturas relevantes, como bordas, texturas e formas.

Após a convolução, aplica-se uma função de ativação não linear, como a Unidade Linear Retificada (ReLU), definida pela Equação 3.1:

$$f(x) = \max(0, x) \quad (3.1)$$

A ReLU introduz não linearidade ao modelo ao anular valores negativos, permitindo que a rede aprenda relações complexas entre os dados e aumente sua capacidade de representação.

Na sequência, camadas de *pooling*, frequentemente do tipo *max-pooling*, reduzem a dimensionalidade espacial dos mapas de características. Esse processo preserva as ativações mais relevantes enquanto diminui o número de parâmetros e o custo computacional, contribuindo também para maior robustez a pequenas variações espaciais.

Por fim, os mapas de características são encaminhados para camadas totalmente conectadas, nas quais ocorre a combinação das representações extraídas ao longo da rede. A camada final geralmente utiliza a função de ativação *softmax*, responsável por converter as saídas em probabilidades associadas a cada classe, permitindo a realização da classificação.

3.4 Redes Neurais Convolucionais

Este estudo investiga a performance de três redes neurais convolucionais bem conhecidas frente à classificação indireta de insetos a partir de danos foliares. A seguir apresentamos uma visão geral de cada uma dessas redes: *Visual Geometry Group* (VGG), *Residual Neural Network* (ResNet), e *Inception*.

3.4.1 VGG - Visual Geometry Group

A Visual Geometry Group (VGG) é uma rede neural convolucional amplamente reconhecida no campo de classificação e detecção de objetos, sendo considerada um dos melhores modelos de visão computacional. Este modelo ganhou destaque no evento ImageNet Challenge de 2014 (SIMONYAN; ZISSERMAN, 2014).

A arquitetura da VGG é composta por 13 camadas convolucionais interligadas com cinco camadas de *pooling* e três camadas totalmente conectadas, com uma função de ativação softmax na última camada. Esta arquitetura é conhecida como VGG16. Um segundo modelo desenvolvido pelos autores foi a VGG19, que possui uma estrutura semelhante à VGG16, mas com três camadas convolucionais adicionais. A arquitetura utiliza filtros pequenos de 3×3 , que

mostrou uma melhoria significativa no desempenho, garantindo o primeiro e o segundo lugar nas categorias de localização e classificação, respectivamente.

3.4.2 ResNet - Residual Neural Network

Quando se trabalha com redes neurais convolucionais, é comum notar que, quanto mais profundo for o modelo, mais representações ele tende a aprender. Porém, (HE et al., 2016) mostrou que, quando um modelo utiliza mais de 30 camadas de profundidade, problemas como desaparecimento/explosão de gradientes e degradação em redes neurais impedem que a rede tenha melhorias, mesmo com a adição de mais camadas. Para superar esse desafio, os autores desenvolveram uma nova estrutura, a *Residual Neural Network* (ResNet). Este modelo resolveu o problema implementando blocos residuais, o que permite o fluxo direto das informações (HE et al., 2016).

O modelo ResNet apresenta diversas arquiteturas com diferentes profundidades, como a tradicional ResNet-50, ResNet-18 e ResNet-32, entre outras. Apesar da ResNet-50 ter sido lançada em 2015, continua sendo um dos melhores modelos de classificação de imagens, com uma estrutura de 48 camadas convolucionais junto com uma camada MaxPool e uma camada AveragePool.

3.4.3 Inception

Enquanto algumas CNNs focavam em aumentar a profundidade da rede para obter resultado melhores, os desenvolvedores da Inception foram os primeiros a pensar em aumentar a largura e a profundidade de forma conjunta. Assim, conseguindo obter melhor desempenho na classificação sem aumentar excessivamente a demanda por recurso computacional.

A estrutura dessa CNN conta com a execução simultânea de três tipos de convoluções: 1×1 , 3×3 , e 5×5 , juntamente com uma camada de Max pooling (3×3). Posteriormente os resultados das três convoluções são concatenados e enviado para o próximo modulo de inicialização. Neste trabalho utilizamos a Inception V3 Szegedy et al. (2016).

3.5 Métricas de Avaliação

Para avaliar o desempenho dos modelos de classificação, foram utilizadas métricas amplamente empregadas em problemas de classificação supervisionada. A escolha dessas métricas fundamenta-se na necessidade de analisar diferentes tipos de erro, especialmente falsos

positivos e falsos negativos. A matriz de confusão foi utilizada como base para o cálculo das métricas derivadas, permitindo uma análise detalhada do comportamento do classificador. Além disso, a curva ROC foi empregada para avaliar o desempenho do modelo em diferentes limiares de decisão, enquanto o método Grad-CAM foi utilizado para fornecer interpretabilidade às predições realizadas.

3.5.1 Matriz Confusão

Matriz confusão é uma métrica bastante utilizada nos campos de *machine learning* e classificação de imagem. A matriz confusão é um tabela que permite visualizar o desempenho do modelo de classificação em termos de verdadeiro positivo (VP), falsos positivo (FP), verdadeiro negativo (VN), e falso negativo (FN).

3.5.2 Precisão

A precisão calcula, dentre todas as classificações positivas que o modelo realizou, quantas dessas estão realmente corretas, conforme apresentado na Eq. 1 . 3.2.

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (3.2)$$

3.5.3 Recall

O recall mede a capacidade do modelo de identificar todos os verdadeiros positivos do conjunto de dados. Ele calcula a proporção de verdadeiros positivos com base em todas as instâncias que o modelo deveria ter classificado como positiva conforme apresentado na Eq.3.3.

$$\text{Recall} = \frac{VP}{VP + FN} \quad (3.3)$$

3.5.4 F1-Score

O F1-score é a media harmônica entre a precisão e o recall, conforme apresentado na Eq. 3.4.

$$\text{F1-score} = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3.4)$$

3.5.5 Acurácia

A acurácia indica a precisão geral do modelo, ou seja, dentre todas as classificações que o modelo apresentou quantas estão corretas, conforme apresentado na Eq.3.5.

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FP + FN} \quad (3.5)$$

3.5.6 Curvas ROC

Em análises preditivas de classificadores, as Curvas ROC são fundamentais para medir o desempenho dos modelos. As curvas ROC mostram o comportamento dos modelos diante da variação nas taxas de verdadeiros e falsos positivos.

3.5.7 Grad-CAM

Quando se trabalha com modelos de visão computacional, sabemos que o classificador acerta algumas predições, mas não sabemos quais recursos da imagem ele utilizou para classificar. Pensando nisso, (SELVARAJU et al., 2017) desenvolveu um método de aprendizado profundo que permite compreender as características importantes que o modelo utilizou para identificar o objeto na imagem, através de mapas de calor.

Neste capítulo são descritos os métodos adotados para a construção do conjunto de dados com danos foliares sintéticos, a estratégia de treinamento das redes neurais convolucionais e a organização dos experimentos realizados.

4.1 Construção do Dataset e Estratégia de Treinamento

4.1.1 Seleção e Segmentação dos Danos Foliares

Na etapa de segmentação manual dos danos foliares, realizou-se inicialmente um levantamento dos principais tipos de danos causados por insetos-praga que afetam o cultivo da soja. Foram selecionadas duas espécies: *Diabrotica speciosa* (Coleoptera: Chrysomelidae — vaquinha-verde) e *Anticarsia gemmatalis* (Lepidoptera: Noctuidae — lagarta-da-soja).

As marcas de dano foram obtidas a partir de folhas previamente danificadas pertencentes à base de dados construída por (MIGNONI et al., 2022). A extração manual das assinaturas de mordida foi realizada com o auxílio do software de edição de imagens GIMP. O procedimento foi estruturado nas seguintes etapas:

1. Delimitação manual das marcas de mordida na imagem original;
2. Remoção cuidadosa das regiões segmentadas;
3. Redimensionamento das imagens extraídas para diferentes dimensões, limitadas a 50×50 pixels;

4. Binarização das imagens, convertendo-as para formato binário, etapa necessária para a aplicação do algoritmo de desfolha sintética.

4.1.2 Simulação de Danos Foliare

A geração de desfolha sintética foi realizada com base no método proposto por (VIEIRA et al., 2024). As imagens foram previamente binarizadas e padronizadas quanto à rotação e à escala, conforme descrito no método original.

A estratégia utiliza imagens modelo construídas a partir de folhas saudáveis, empregando uma métrica de similaridade estrutural (IoU) para estimativa da área foliar ausente.

No presente trabalho, o algoritmo foi utilizado para aplicar danos artificiais em folhas saudáveis por meio de assinaturas de mordida previamente segmentadas. As amostras de dano foram submetidas a transformações aleatórias de escala e rotação e aplicadas tanto nas regiões internas quanto nas bordas da folha.

Foram considerados três níveis de severidade: leve (1–15%), moderado (16–30%) e severo (31–45%). Ao final, foi construída uma base com 1.758 imagens sintéticas de dimensão 256×256 pixels.

A Figura 4.2 apresenta o fluxograma geral do processo metodológico adotado, desde a extração manual dos danos até o treinamento e avaliação das redes neurais convolucionais.

As etapas de treinamento e avaliação dos modelos, ilustradas na Figura 4.2, são descritas nas seções seguintes.

4.1.3 Transferência de Aprendizado

Foram avaliadas três arquiteturas distintas de redes neurais convolucionais com o objetivo de comparar seus desempenhos na tarefa proposta. Para garantir um ponto de partida comum, empregou-se a técnica de transferência de aprendizado utilizando modelos previamente treinados na base ImageNet (RUSSAKOVSKY et al., 2015).

Redes treinadas na ImageNet aprendem representações hierárquicas gerais, como detectores de bordas, texturas e padrões visuais complexos, que podem ser reutilizadas em tarefas específicas com menor volume de dados.

Para adaptação ao problema deste estudo, as camadas totalmente conectadas originais responsáveis pela classificação em 1000 classes foram removidas e substituídas por:

uma camada `Flatten`;




Figura 4.1: Amostra do banco dados com danos construídos artificialmente.




Figura 4.2: Fluxograma do processo metodológico adotado

uma camada totalmente conectada com ativação ReLU;
uma camada Dropout com taxa de 0.5;
uma camada totalmente conectada final com ativação Softmax, com número de neurônios correspondente às classes do estudo.

Foram avaliadas diferentes estratégias de ajuste fino (fine-tuning). Inicialmente, apenas as camadas finais foram mantidas treináveis, mantendo-se a maior parte do modelo base congelada. Posteriormente, camadas convolucionais foram gradualmente descongeladas, permitindo analisar o impacto do nível de adaptação das representações pré-treinadas ao conjunto de dados.

4.2 Organização do Experimento

Nesta seção são apresentados os procedimentos adotados para condução dos experimentos, incluindo a separação dos dados, a configuração do ambiente computacional e os critérios de avaliação.

4.2.1 Separação dos Dados

O conjunto total de 2.634 imagens foi dividido em três subconjuntos: treinamento (1.716 imagens), validação (612 imagens) e teste (306 imagens). A divisão foi realizada de forma estratificada, preservando a proporção de amostras de cada classe.

A distribuição por classe foi a seguinte:

- **Lagarta-da-soja:** 734 imagens para treino, 204 para validação e 102 para teste (1.040 no total);
- **Vaquinha-verde:** 702 imagens para treino, 204 para validação e 102 para teste (1.008 no total);
- **Folha saudável:** 280 imagens para treino, 204 para validação e 102 para teste (586 no total).

A divisão estratificada garante representatividade das classes em todas as etapas, reduzindo viés nas métricas de desempenho.

4.3 Preparação dos Modelos

A análise consistiu na classificação de folhas em três classes: *Diabrotica speciosa* (vaquinha-verde), *Anticarsia gemmatalis* (lagarta-da-soja) e folha saudável.

Foram avaliadas as arquiteturas VGG-16 (SIMONYAN; ZISSERMAN, 2014), ResNet-50 (HE et al., 2016) e Inception-V3 (SZEGEDY et al., 2016). As imagens foram redimensionadas para atender aos requisitos das arquiteturas e organizadas nos diretórios de treino, validação e teste. A implementação foi realizada em Python no ambiente Google Colab, utilizando o framework TensorFlow (ABADI et al., 2015) com a API de alto nível Keras (CHOLLET et al., 2015). O treinamento utilizou GPU disponibilizada pelo ambiente, com suporte a CUDA.

Cada modelo foi treinado, em média, por 37 épocas.

As configurações utilizadas no desenvolvimento são apresentadas na figura abaixo:

NVIDIA-SMI 535.104.05				Driver Version: 535.104.05		CUDA Version: 12.2	
GPU	Name		Persistence-M	Bus-Id	Disp.A	Volatile	Uncorr. ECC
Fan	Temp	Perf	Pwr:Usage/Cap		Memory-Usage	GPU-Util	Compute M.
							MIG M.
0	Tesla T4		Off	00000000:00:04.0	Off		0
N/A	61C	P8	11W / 70W	0MiB / 15360MiB		0%	Default
							N/A

Processes:							
GPU	GI	CI	PID	Type	Process name	GPU Memory	
	ID	ID				Usage	
No running processes found							

Figura 4.3: Configurações do *Google Colab*.

4.4 Construção dos Modelos

O processo experimental seguiu as seguintes etapas:

1. Montagem do Google Drive e carregamento do conjunto de dados no ambiente Google Colab;
2. Organização dos dados em treino, validação e teste;
3. Treinamento individual das três arquiteturas em notebooks distintos;

4. Salvamento dos modelos treinados e dos rótulos para análises posteriores.

4.4.1 Coleta de Dados

Ao final do treinamento, foram coletadas as métricas de Acurácia, Precisão, Recall e F1-score para cada modelo.

4.4.2 Avaliação dos Resultados

O desempenho foi avaliado com base nas métricas descritas na Seção 3.5. A matriz de confusão foi utilizada para identificar verdadeiros positivos (VP), falsos positivos (FP), falsos negativos (FN) e verdadeiros negativos (VN).

As métricas de precisão, recall e F1-score foram calculadas a partir desses valores.

Além disso, foi utilizado o método Grad-CAM para visualizar as regiões das imagens que mais contribuíram para as decisões das redes neurais, permitindo analisar se os modelos concentraram sua atenção nas áreas de dano foliar.

CAPÍTULO 5

RESULTADOS E DISCUSSÃO

As Tabelas 5.1, 5.2 e 5.3 apresentam o desempenho das arquiteturas VGG16, ResNet50 e InceptionV3 na tarefa de classificação de insetos com base nos danos presentes nas folhas. De modo geral, as três arquiteturas apresentaram elevado desempenho, especialmente na classificação da classe folha saudável. Observa-se ainda que a ResNet50 obteve os maiores valores de *recall* para a classe lagarta-da-soja e de precisão para a classe vaquinha verde, indicando maior capacidade de identificação correta dessas classes. A seguir, os resultados são discutidos individualmente para cada arquitetura.

A Tabela 5.1 apresenta os resultados de precisão por classe. Observa-se que a VGG16 apresentou maior precisão na classe folha saudável (0,98). A ResNet50 destacou-se ao atingir precisão de 1,00 para a classe vaquinha verde. Para a classe lagarta-da-soja, tanto ResNet50 quanto VGG16 obtiveram o mesmo valor de precisão (0,93).

Tabela 5.1: Precisão por classe

Rede	Folha Saudável	Vaquinha Verde	Lagarta-da-soja
ResNet50	0.97	1.00	0.93
InceptionV3	0.96	0.97	0.90
VGG16	0.98	0.96	0.93

Os resultados de *recall* são apresentados na Tabela 5.2. A ResNet50 obteve o maior valor de *recall* para a classe lagarta-da-soja (0,98), evidenciando maior capacidade de identificar corretamente amostras dessa classe. No entanto, para a classe vaquinha verde, o *recall* foi inferior ao observado na VGG16, indicando maior ocorrência de falsos negativos. A classe folha saudável apresentou valores elevados em todas as arquiteturas.

Tabela 5.2: *Recall* por classe

Rede	Folha Saudável	Vaquinha Verde	Lagarta-da-soja
ResNet50	0.99	0.92	0.98
InceptionV3	0.97	0.88	0.97
VGG16	0.98	0.93	0.96

A Tabela 5.3 apresenta os valores de *F1-score*. Observa-se desempenho competitivo entre as arquiteturas, com destaque para a ResNet50 e VGG16, que apresentaram valores mais elevados de *F1-score* na maioria das classes. A InceptionV3 demonstrou maior dificuldade na classificação da classe vaquinha verde, refletindo o menor valor de *recall* observado anteriormente.


Tabela 5.3: *F1-Score* por classe

Rede	Folha Saudável	Vaquinha Verde	Lagarta-da-soja
ResNet50	0.98	0.96	0.95
InceptionV3	0.97	0.92	0.93
VGG16	0.98	0.95	0.95


As matrizes de confusão das três redes utilizadas são apresentadas na Figura 5.1. As diagonais principais dessas matrizes representam a acurácia por classe, isto é, a proporção de amostras corretamente classificadas em cada categoria (vaquinha verde, lagarta-da-soja e folha saudável).

A matriz de confusão da VGG16 indica uma acurácia de 98% para a classe folha saudável, 93% para vaquinha verde e 96% para lagarta-da-soja. Para a InceptionV3, observa-se uma acurácia de 97% na classe folha saudável, 88,2% para vaquinha verde e 97% para lagarta-da-soja. Já a ResNet50 apresentou acurácia de 98% para folha saudável, 78% para vaquinha verde e 97% para lagarta-da-soja.


A partir da matriz confusão, é possível observar que os três modelos apresentaram elevado desempenho na classificação das classes analisadas, com destaque para a classe folha saudável, que obteve altos valores de acurácia em todas as arquiteturas. No entanto os modelos apresentaram maior dificuldades de classificação para classe vaquinha verde, especialmente a ResNet50, que obteve o menor valor de acurácia (78%) em comparação com a VGG16 e a InceptionV3. Esses resultados indicam que, embora os modelos sejam capazes de diferenciar os insetos a partir dos danos foliares, a identificação da vaquinha verde permanece como um desafio relativo, possivelmente devido à semelhança visual dos danos causados pela lagarta da soja.



(a) VGG16



(b) InceptionV3



(c) ResNet50


Figura 5.1: Matrizes confusão com a predição e os resultados usando VGG16, ResNet50 e InceptionV3.

A figura 5.2 apresenta os resultados ao converter o problema de multi-classificação em uma abordagem binária. Com objetivo de somente classificar se um dano presente nas folhas foi causado por uma classe ou não. Nesse contexto, cada classe é considerada como positiva, enquanto as demais são agrupadas como negativas, permitindo avaliar a capacidade discriminativa do modelo para cada tipo de dano foliar.


Observa-se que todas as arquiteturas avaliadas apresentaram desempenho elevado, com valores de área sob a curva (AUC) variando entre 0.98 e 1.00, indicando excelente separabilidade entre as classes. A classe folha saudável obteve, de modo geral, os maiores valores de AUC, chegando a 1.00 na arquitetura VGG16, o que sugere que o modelo identifica com maior facilidade padrões associados à ausência de danos.

Para as classes vaquinha verde e lagarta-da-soja, embora os valores de AUC também sejam elevados, nota-se uma ligeira redução em comparação à classe saudável, o que pode ser atribuído à semelhança visual entre os padrões de dano causados por diferentes insetos. Ainda assim, as curvas permanecem significativamente acima da linha de acaso, demonstrando que os modelos aprenderam características discriminativas relevantes para a identificação das pragas.


Esses resultados corroboram as métricas quantitativas previamente apresentadas e reforçam a robustez das arquiteturas avaliadas, evidenciando sua capacidade de generalização mesmo em cenários de maior complexidade visual.



(a) VGG16



(b) InceptionV3



(c) Resnet-50

Figura 5.2: Curvas ROC usando arquiteturas VGG16, ResNet50 e InceptionV3.

A Figura 5.3 apresenta os mapas de ativação das 13 camadas da VGG16. Nota-se que as camadas iniciais, representadas na parte inferior da figura, equivalem predominantemente a padrões de baixo nível, como bordas e contornos da folha. À medida que a profundidade aumenta, o mapa de calor torna-se progressivamente mais concentrado nas regiões associadas à perda foliar causada pela predação de insetos.




Figura 5.3: Mapas de ativação das camadas convolucionais VGG16 usando Grad-CAM.

Esse comportamento demonstra o aprendizado hierárquico da VGG16, no qual características simples como bordas são gradualmente combinadas para formar representações mais discriminativas. As camadas mais profundas evidenciam maior sensibilidade às regiões danificadas da folha, indicando que o modelo também utiliza dessas informações relacionadas aos padrões de dano para realizar a inferência acerca do inseto responsável, tendo correlação com a hipótese de que os danos foliares expõem atributos distintivos entre as classes.

Porém, é importante evidenciar, que algumas ativações ainda ocorrem em regiões periféricas ou em aspectos fora da folha em si, o que sugere uma limitação do modelo em isolar

completamente a área foliar. Esse comportamento está associado à constituição do dataset que foi implementado em um ambiente controlado onde não apresenta variabilidade do fundo da imagem. Ainda assim, os mapas Grad-CAM contribuem significativamente para a interpretabilidade do modelo, demonstrando evidências visuais de que o modelo utiliza danos foliares como um dos fatores de decisão para classificação.

Os resultados obtidos neste trabalho podem ser comparados aos apresentados por (MIGNONI et al., 2025), que também investigam a identificação de pragas da soja a partir da análise de danos foliares utilizando redes neurais convolucionais. Enquanto aquele estudo utiliza imagens reais capturadas por UAV em ambiente natural, sujeitas a variações de iluminação, fundo e sobreposição de danos, o presente trabalho adota uma abordagem baseada em danos foliares sintéticos, permitindo maior controle sobre a morfologia visual das lesões.

Apesar dessas diferenças, observa-se convergência nos resultados quanto à maior facilidade de classificação da classe folha saudável e à maior dificuldade associada à classe vaquinha verde, indicando que a similaridade visual dos padrões de dano constitui um desafio intrínseco ao problema. No entanto, os elevados valores de recall e AUC observados neste estudo sugerem que, em condições controladas, os padrões de dano foliar contêm informação discriminativa suficiente para a identificação das pragas. Esses achados reforçam a hipótese assumida por Mignoni et al. (2025) de que a desfolha pode ser utilizada como proxy visual para identificação de insetos, ao mesmo tempo em que indicam que a degradação de desempenho em cenários reais está fortemente associada à complexidade visual do ambiente agrícola.

A Tabela 5.4 sintetiza as principais diferenças metodológicas entre o presente trabalho e o estudo de Mignoni et al. (2025). Observa-se que, enquanto aquele estudo prioriza a validação da abordagem em ambiente real, o presente trabalho investiga de forma controlada a capacidade discriminativa dos padrões visuais de dano foliar. Essa diferença metodológica permite interpretar os resultados como complementares, indicando que os elevados desempenhos observados neste trabalho representam um limite superior do potencial da abordagem baseada em danos, ao passo que os resultados de Mignoni et al. (2025) refletem os desafios adicionais impostos por cenários agrícolas reais.

Tabela 5.4: Comparação entre o presente trabalho e o estudo de Mignoni et al. (2025) na identificação de pragas a partir de danos foliares.

Aspecto	Presente trabalho	Mignoni et al. (2025)
Tipo de imagem	Danos foliares sintéticos aplicados sobre imagens de folhas	Imagens naturais capturadas em campo
Ambiente de aquisição	Ambiente controlado	Ambiente real (campo agrícola)
Fonte das imagens	Base deriva da Hughes et al Dataset com inserção de danos sintéticos	Imagens coletadas por UAV em lavouras de soja
Objetivo principal	Avaliar a capacidade discriminativa dos padrões visuais de dano foliar	Identificar pragas a partir da desfolha em condições reais
Classes analisadas	Lagarta-da-soja, vaquinha verde e folha saudável	Lagarta, <i>Diabrotica speciosa</i> e folha saudável
Arquiteturas avaliadas	VGG16, ResNet50 e InceptionV3	VGG16, VGG19, ResNet50, DenseNet201 e Efficient-NetB7
Melhor arquitetura	ResNet50 (recall) e VGG16 (precisão/F1)	VGG16
Desempenho global	F1-score e AUC próximos de 1.0 para todas as classes	Acurácia média de 0.95 (validação) e 0.86 (teste)
Classe com maior dificuldade	Vaquinha verde	<i>Diabrotica speciosa</i>
Análise interpretável	Grad-CAM evidenciando focos nos danos foliares	Análise baseada em métricas globais e matrizes de confusão
Principal contribuição	Validação da hipótese visual em cenário controlado	Demonstração de viabilidade em cenário real

Este trabalho teve como objetivo propor um modelo de classificação automática de danos foliares na cultura da soja, causados por besouros e lagartas, utilizando redes neurais convolucionais. A abordagem adotada demonstrou que é possível obter resultados expressivos na identificação dos danos, contribuindo para práticas mais precisas de monitoramento agrícola. O desenvolvimento foi realizado com o uso dos *frameworks* TensorFlow e Keras, empregando as arquiteturas InceptionV3, ResNet-50 e VGG-16 e utilizando a transferência de aprendizado. Entre os modelos avaliados, a VGG-16 obteve o melhor desempenho, com acurácia de 95,75%.

De modo geral, os resultados obtidos indicam o potencial do uso de redes neurais convolucionais como ferramenta de apoio ao diagnóstico visual de pragas agrícolas de maneira prematura, especialmente quando integradas a aparelhos acessíveis, como aplicações móveis.

5.1 Trabalhos Futuros

Dando continuidade à pesquisa, propõe-se a validação do modelo em imagens contendo danos reais causados por *Anticarsia gemmatilis* (lagarta da soja) e *Diabrotica speciosa* (vaquinha-verde), com o objetivo de avaliar sua capacidade de generalização em condições de campo. Embora estudos prévios tenham explorado cenários reais, a aplicação do modelo desenvolvido neste trabalho nesse contexto permitirá verificar sua robustez frente às variações de luminosidade e estágio fenológico da cultura e padrões naturais de dano.

Adicionalmente, pretende-se desenvolver um aplicativo móvel capaz de realizar a classificação dos danos foliares em tempo real, com funcionamento offline, viabilizando sua utilização prática no campo. Como aprofundamento metodológico, sugere-se investigar arquiteturas mais recentes e mecanismos de atenção, buscando aprimorar a extração de características discri-

minativas, especialmente para *Diabrotica speciosa*, cuja identificação pode apresentar maior variabilidade visual.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABADI, M.; AGARWAL, A.; BARHAM, P.; BREVDIO, E.; CHEN, Z.; CITRO, C.; CORRADO, G. S.; DAVIS, A.; DEAN, J.; DEVIN, M. et al. *TensorFlow: Large-scale machine learning on heterogeneous systems*. [S.l.]: Mountain View, CA: Tensorflow, 2015.
- AVILA-GEORGE, H.; VALDEZ-MORONES, T.; PÉREZ-ESPINOSA, H.; ACEVEDO-JUÁREZ, B.; CASTRO, W. Using artificial neural networks for detecting damage on tobacco leaves caused by blue mold. *Strategies*, v. 9, n. 8, 2018.
- BIJLWAN, A.; RANJAN, R.; POKHARIYAL, S.; GOVIND, A.; SINGH, M.; SINGH, K. P.; SINGH, R. K.; RAJPUT, R. K. S.; SRIVASTAVA, R. K. Enhancing rice disease and insect-pest detection through augmented deep learning with transfer learning techniques. *Smart Agricultural Technology*, Elsevier, p. 100954, 2025.
- BORLAUG, N. E. The green revolution revisited and the road ahead. In: . [s.n.], 2017. Disponível em: <<https://api.semanticscholar.org/CorpusID:12689475>>.
- CHEN, X.; LIU, T.; HAN, K.; JIN, X.; WANG, J.; KONG, X.; YU, J. Tsp-yolo-based deep learning method for monitoring cabbage seedling emergence. *European Journal of Agronomy*, Elsevier, v. 157, p. 127191, 2024.
- CHOLLET, F. et al. *keras*. [S.l.]: Seattle, WA, USA, 2015.
- CHOWANDA, A.; CHOWANDA, A. D. Recurrent neural network to deep learn conversation in indonesian. p. 579–586, 2017.
- DOAN, T.-N.; NGUYEN, C. V. A low-cost digital 3d insect scanner. *Information Processing in Agriculture*, 2023. ISSN 2214-3173. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2214317323000471>>.
- DOMÊNICO, J. R. D.; LAU, D.; RIBEIRO, D. D.; RIEDER, R.; JÚNIOR, T. D. C. Um estudo comparativo de redes convolucionais profundas para detecção de insetos em imagens. In: SBC. *Anais Estendidos do XXXIV Conference on Graphics, Patterns and Images*. [S.l.], 2021. p. 183–188.
- FENG, J.; WANG, Z.; WANG, S.; TIAN, S.; XU, H. Msdd-yolox: An enhanced yolox for real-time surface defect detection of oranges by type. *European Journal of Agronomy*, Elsevier, v. 149, p. 126918, 2023.

FU, X.; MA, Q.; YANG, F.; ZHANG, C.; ZHAO, X.; CHANG, F.; HAN, L. Crop pest image recognition based on the improved vit method. *Information Processing in Agriculture*, 2023. ISSN 2214-3173. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2214317323000173>>.

GARCIA, B. C.; PERICO, D. H. Classificação de insetos com o uso de redes neurais convolucionais. In: *XII Simpósio de Iniciação Científica, Didática e de Ações Sociais da FEI*. [S.l.: s.n.], 2018.

GOSHIKA, S.; MEKSEM, K.; AHMED, K. R.; LAKHSSASSI, N. Deep learning model for classifying and evaluating soybean leaf disease damage. *International Journal of Molecular Sciences*, v. 25, n. 1, 2024. ISSN 1422-0067. Disponível em: <<https://www.mdpi.com/1422-0067/25/1/106>>.

HE, K.; ZHANG, X.; REN, S.; SUN, J. 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.

HUGHES, D.; SALATHÉ, M. et al. An open access repository of images on plant health to enable the development of mobile disease diagnostics. *arXiv preprint arXiv:1511.08060*, 2015.

HUGHES, D.; SALATHÉ, M. et al. An open access repository of images on plant health to enable the development of mobile disease diagnostics. *arXiv preprint arXiv:1511.08060*, 2015.

JÚNIOR, T. D. C. et al. Insectcv: um sistema para detecção de insetos em imagens digitais. *testee*, Universidade de Passo Fundo, 2020.

JÚNIOR, T. D. C.; RIEDER, R. Automatic identification of insects from digital images: A survey. *Computers and electronics in agriculture*, Elsevier, v. 178, p. 105784, 2020.

LEVIN, G. *Controle de pragas agrícolas*. 2017. Acesso em 17 de maio de 2024. Disponível em: <<http://www.bayer.com.br/pt/blog/controle-de-pragas-agricolas>>.

LI, R.; SUN, G.; WANG, S.; TAN, T.; XU, F. Tree trunk detection in urban scenes using a multiscale attention-based deep learning method. *Ecological Informatics*, Elsevier, v. 77, p. 102215, 2023.

MIGNONI, M. E.; HONORATO, A.; KUNST, R.; RIGHI, R.; MASSUQUETTI, A. Soybean images dataset for caterpillar and diabrotica speciosa pest detection and classification. *Data in Brief*, Elsevier, v. 40, p. 107756, 2022.

MIGNONI, M. E.; HONORATO, A.; ZAGONEL, C.; RAMOS, G. de O.; KUNST, R. K. Amipdi: architecture model to identify pests in soybean defoliation images using convolutional neural networks. *Revista Brasileira de Computação Aplicada*, v. 17, n. 2, p. 11–20, 2025.

OWEN, L.; CATCHOT, A.; MUSSER, F.; GORE, J.; COOK, D.; JACKSON, R.; ALLEN, C. Impact of defoliation on yield of group iv soybeans in mississippi. *Crop Protection*, Elsevier, v. 54, p. 206–212, 2013.

RUSSAKOVSKY, O.; DENG, J.; SU, H.; KRAUSE, J.; SATHEESH, S.; MA, S.; HUANG, Z.; KARPATY, A.; KHOSLA, A.; BERNSTEIN, M. et al. Imagenet large scale visual recognition challenge. *International journal of computer vision*, Springer, v. 115, p. 211–252, 2015.

RUSTIA, D. J. A.; LEE, W.-C.; LU, C.-Y.; WU, Y.-F.; SHIH, P.-Y.; CHEN, S.-K.; CHUNG, J.-Y.; LIN, T.-T. Edge-based wireless imaging system for continuous monitoring of insect pests in a remote outdoor mango orchard. *Computers and Electronics in Agriculture*, v. 211, p. 108019, 2023. ISSN 0168-1699. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0168169923004076>>.

SELVARAJU, R. R.; COGSWELL, M.; DAS, A.; VEDANTAM, R.; PARIKH, D.; BATRA, D. Grad-cam: Visual explanations from deep networks via gradient-based localization. In: *Proceedings of the IEEE international conference on computer vision*. [S.l.: s.n.], 2017. p. 618–626.

SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.

SZEGEDY, C.; VANHOUCKE, V.; IOFFE, S.; SHLENS, J.; WOJNA, Z. Rethinking the inception architecture for computer vision. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 2818–2826.

VIEIRA, G. D. S.; SOUSA, N. M. de; ROCHA, B.; FONSECA, A. U.; SOARES, F. A method for the detection and reconstruction of foliar damage caused by predatory insects. In: *IEEE. 2021 IEEE 45th Annual Computers, Software, and Applications Conference (COMPSAC)*. [S.l.], 2021. p. 1502–1507.

VIEIRA, G. da S.; ROCHA, B. M.; FONSECA, A. U.; SOUSA, N. M. de; FERREIRA, J. C.; CABACINHA, C. D.; SOARES, F. Automatic detection of insect predation through the segmentation of damaged leaves. *Smart Agricultural Technology*, Elsevier, v. 2, p. 100056, 2022. ISSN 2772-3755. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2772375522000211>>.

VIEIRA, G. da S.; ROCHA, B. M.; SOARES, F.; LIMA, J. C.; PEDRINI, H.; COSTA, R.; FERREIRA, J. Extending the aerial image analysis from the detection of tree crowns. In: *IEEE. 2019 IEEE 31st International Conference on Tools with Artificial Intelligence (ICTAI)*. [S.l.], 2019. p. 1681–1685.

VIEIRA, G. da S.; SOARES, F. A.; LIMA, J. C. de; LAUREANO, G. T.; SANTOS, S. A.; COSTA, R. M.; SALVINI, R. Trunk detection and tree disparity calculation in uncontrolled environments. In: *IEEE. 2019 IEEE Symposium on Computers and Communications (ISCC)*. [S.l.], 2019. p. 1–6.

VIEIRA, G. S.; FONSECA, A. U.; de Sousa, N. M.; FERREIRA, J. C.; FELIX, J. P.; CABACINHA, C. D.; SOARES, F. An automatic method for estimating insect defoliation with visual highlights of consumed leaf tissue regions. *Information Processing in Agriculture*, 2024. ISSN 2214-3173. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2214317324000192>>.

VIEIRA, G. S.; FONSECA, A. U.; FERREIRA, J. C.; SOARES, F. Protectleaf: An insect predation analyzer for agricultural crop monitoring. *SoftwareX*, v. 24, p. 101537, 2023. ISSN 2352-7110. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2352711023002339>>.

VIEIRA, G. S.; FONSECA, A. U.; ROCHA, B. M.; SOUSA, N. M.; FERREIRA, J. C.; FELIX, J. P.; LIMA, J. C.; SOARES, F. Insect predation estimate using binary leaf models and image-matching shapes. *Agronomy*, MDPI, v. 12, n. 11, p. 2769, 2022. ISSN 2073-4395. Disponível em: <<https://www.mdpi.com/2073-4395/12/11/2769>>.

VIEIRA, G. S.; FONSECA, A. U.; SOUSA, N. M. de; FERREIRA, J. C.; FELIX, J. P.; CABACINHA, C. D.; SOARES, F. An automatic method for estimating insect defoliation with visual highlights of consumed leaf tissue regions. 2024.

YANG, Z.; YANG, X.; LI, M.; LI, W. Automated garden-insect recognition using improved lightweight convolution network. *Information Processing in Agriculture*, v. 10, n. 2, p. 256–266, 2023. ISSN 2214-3173. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2214317321000986>>.

ZHANG, M.; LIANG, H.; WANG, Z.; WANG, L.; HUANG, C.; LUO, X. Damaged apple detection with a hybrid yolov3 algorithm. *Information Processing in Agriculture*, 2022. ISSN 2214-3173. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2214317322000889>>.

ZHU, L.; LI, X.; SUN, H.; HAN, Y. Research on cbf-yolo detection model for common soybean pests in complex environment. *Computers and Electronics in Agriculture*, Elsevier, v. 216, p. 108515, 2024.