

UNIVERSIDADE DE SÃO PAULO

Instituto de Ciências Matemáticas e de Computação

Identificação de Doenças e Estresses Nutricionais em Soja Utilizando Visão Computacional e Aprendizagem por Transferência

Lobato Nonato Souza

Monografia - MBA em Inteligência Artificial e Big Data

SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito:

Assinatura: _____

Lobato Nonato Souza

Identificação de Doenças e Estresses Nutricionais em Soja Utilizando Visão Computacional e Aprendizagem por Transferência

Monografia apresentada ao Departamento de Ciências de Computação do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, como parte dos requisitos para obtenção do título de Especialista em Inteligência Artificial e Big Data.

Área de concentração: Inteligência Artificial

Orientador: Prof. Dr. Ricardo Cerri

Versão original

São Carlos

2025

AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTES
TRABALHOS, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/USP,
com os dados inseridos pelo(a) autor(a)

S719i Souza, Lobato Nonato
Identificação de Doenças e Estresses Nutricionais
em Soja Utilizando Visão Computacional e Aprendizado
por Transferência / Lobato Nonato Souza; orientador
Ricardo Cerri. -- São Carlos, 2025.
59 p.

Trabalho de conclusão de curso (MBA em
Inteligência Artificial e Big Data) -- Instituto de
Ciências Matemáticas e de Computação, Universidade
de São Paulo, 2025.

1. Agricultura de Precisão. 2. Visão
Computacional. 3. Aprendizado Profundo. 4.
Aprendizagem por Transferência. 5. Soja. I. Cerri,
Ricardo, orient. II. Título.

Lobato Nonato Souza

Identification of Diseases and Nutritional Stresses in Soybean Using Computer Vision and Transfer Learning

Monograph presented to the Departamento de Ciências de Computação do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, as part of the requirements for obtaining the title of Specialist in Artificial Intelligence and Big Data.

Concentration area: Artificial Intelligence

Advisor: Prof. Dr. Ricardo Cerri

Original version

São Carlos

2025

*À minha esposa, **Leila Dark**, a quem dedico este trabalho de forma especial. Seu amor, apoio incondicional, paciência e compreensão foram fundamentais em cada etapa desta jornada. Sem a sua presença e paciência, nada disso teria sido possível.*

*Aos meus filhos, **Igor, Davi e Sofia**, que me enchem de orgulho e são minha maior fonte de inspiração e motivação para seguir sempre em frente.*

E, com todo o apreço, aos meus pais, que desde a minha infância me ensinaram o valor do estudo e nunca permitiram que eu desistisse.

*Ao **Instituto de Ciências Matemáticas e de Computação da USP (ICMC/USP)**, pela oportunidade de aprendizado e pela contribuição decisiva na aquisição dos conhecimentos que tornaram este trabalho possível.*

AGRADECIMENTOS

A Deus, pela vida, saúde e pela oportunidade de chegar até aqui.

À minha esposa, **Leila Dark**, por seu amor, apoio e compreensão em cada momento desta jornada. Aos meus filhos, **Igor, Davi e Sofia**, que enchem meus dias de alegria e me motivam a seguir adiante.

Ao meu orientador, **Prof. Dr. Ricardo Cerri**, pela orientação, paciência e dedicação durante todo o desenvolvimento deste trabalho, contribuindo de forma decisiva para minha formação e para a qualidade desta pesquisa.

À Coordenadora do Curso, **Prof^a Dra. Solange Oliveira Rezende**, pelo compromisso com a excelência acadêmica e pela condução exemplar do MBA em Inteligência Artificial e Big Data no ICMC/USP.

Ao **Instituto de Ciências Matemáticas e de Computação da USP (ICMC/USP)**, pela infraestrutura, recursos e ambiente acadêmico que possibilitaram a realização deste trabalho.

Aos professores que ministraram aulas e tutorias ao longo do MBA, pela dedicação e pelo compartilhamento de conhecimento, fundamentais para minha formação.

Aos colegas de curso, pela amizade, apoio e pelas valiosas trocas de conhecimento que tornaram esta jornada mais enriquecedora.

Por fim, a todos que, de forma direta ou indireta, contribuíram para a concretização deste TCC, registro aqui meu mais sincero agradecimento.

*“Por trás da IA não há consciência ou raciocínio,
apenas o cálculo incessante de probabilidades.”*

(Gerado em diálogo com ChatGPT)

RESUMO

SOUZA, L. N. **Identificação de Doenças e Estresses Nutricionais em Soja Utilizando Visão Computacional e Aprendizagem por Transferência**. 2025. 59 p. Monografia (MBA em Inteligência Artificial e Big Data) - Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2025.

A detecção precoce de doenças e déficits nutricionais é um fator determinante para a sustentabilidade e a eficiência da produção agrícola moderna. Contudo, os métodos convencionais de monitoramento apresentam limitações de escala e agilidade, o que frequentemente resulta em perdas produtivas e no uso ineficiente de insumos. O objetivo deste trabalho foi desenvolver e validar um modelo computacional baseado em Redes Neurais Convolucionais para a detecção e identificação automática de um conjunto de estresses bióticos e abióticos em folhas de soja, a partir de imagens digitais. A metodologia foi fundamentada na Aprendizagem por Transferência, utilizando uma arquitetura ResNet-50 pré-treinada sobre o dataset público ASDID. O treinamento empregou amostragem ponderada para mitigar o desbalanceamento de classes e foi otimizado por meio de uma fase de Ajuste Fino para especializar o modelo ao domínio do problema. O modelo final alcançou uma acurácia global de 96,83% no conjunto de teste, validado por métricas estatísticas que atestam uma concordância “quase perfeita” ($kappa = 0.9631$) e um poder de discriminação excepcional (AUC média = 0.9995). Conclui-se que a abordagem proposta estabelece uma base tecnológica robusta para o desenvolvimento de ferramentas de apoio à decisão, reforçando o potencial da Inteligência Artificial para um monitoramento agrícola mais eficiente e orientado por dados.

Palavras-chave: agricultura de precisão; visão computacional; aprendizado profundo; aprendizagem por transferência; soja.

ABSTRACT

SOUZA, L. N. **Identification of Diseases and Nutritional Stresses in Soybean Using Computer Vision and Transfer Learning**. 2025. 59 p. Monograph (MBA in Artificial Intelligence and Big Data) - Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2025.

The early detection of diseases and nutritional deficits is a determining factor for the sustainability and efficiency of modern agricultural production. However, conventional monitoring methods present limitations in scale and agility, often resulting in production losses and the inefficient use of inputs. The objective of this work was to develop and validate a computational model based on Convolutional Neural Networks for the automatic detection and identification of a set of biotic and abiotic stresses in soybean leaves from digital images. The methodology was based on Transfer Learning, using a pre-trained ResNet-50 architecture on the public ASDID dataset. The training employed weighted sampling to mitigate class imbalance and was optimized through a Fine-Tuning phase to specialize the model to the problem domain. The final model achieved an overall accuracy of 96.83% on the test set, validated by statistical metrics attesting to an “almost perfect” agreement ($kappa = 0.9631$) and exceptional discrimination power (mean AUC = 0.9995). It is concluded that the proposed approach establishes a robust technological foundation for the development of decision support tools, reinforcing the potential of Artificial Intelligence for a more efficient and data-driven agricultural monitoring.

Keywords: precision agriculture; computer vision; deep learning; transfer learning; soybean.

LISTA DE FIGURAS

Figura 1 – Amostras visuais das categorias do conjunto de dados ASDID	35
Figura 2 – Boxplot da Área por Categoria	36
Figura 3 – Histogramas da Distribuição Geral de Área e Proporção	37
Figura 4 – Gráficos de dispersão das resoluções por categoria com eixos globais (fixos).	37
Figura 5 – Gráficos de dispersão das resoluções por categoria com eixos locais (dinâmicos).	38
Figura 6 – Curvas de Aprendizagem da Fase de TL.	41
Figura 7 – Curvas de Aprendizado da Fase de ajuste fino	42
Figura 8 – Matriz de confusão normalizada por classe para o conjunto de teste. A diagonal principal representa a porcentagem de acertos para cada classe.	43
Figura 9 – Histograma de densidade para a distribuição de confiança do modelo. A distribuição para predições corretas (verde) concentra-se em alta confiança, enquanto as incorretas (vermelho) apresentam menor confiança.	45
Figura 10 – Inspeção visual de uma amostra de erros de classificação	46
Figura 11 – Curva Característica de Operação do Receptor (ROC) para o conjunto de teste. São exibidas as curvas para cada classe, bem como as de micro e macro-average, que indicam a performance agregada do modelo. . . .	47

LISTA DE TABELAS

Tabela 1	–	Categorias de estresse biótico e abiótico do Conjunto de Dados ASDID	33
Tabela 2	–	Distribuição Final de Imagens por Categoria após Curadoria	35
Tabela 3	–	Resumo Estatístico dos Atributos Numéricos das Imagens	36
Tabela 4	–	Contagem de outliers superiores por categoria e atributo (método IQR)	38
Tabela 5	–	Distribuição Estratificada das Imagens por Categoria e Subconjunto . .	39
Tabela 6	–	Relatório de classificação detalhado com as métricas de Precision, Recall e F1-Score por classe, e a acurácia geral do modelo.	44
Tabela 7	–	Análise de Custo de Erro por Classe, com as respectivas Taxas de Falsos Positivos (FPR) e Falsos Negativos (FNR).	44
Tabela 8	–	Área Sob a Curva (AUC) por Classe e Média Agregada no Conjunto de Teste. Valores mais próximos de 1.0 indicam maior poder de discrimi- nação do modelo.	45

LISTA DE ABREVIATURAS E SIGLAS

ABNT –	Associação Brasileira de Normas Técnicas
abnTeX –	Sistema para elaboração de documentos científicos conforme as normas da ABNT em $\LaTeX$
AED –	Análise Exploratória de Dados (<i>Exploratory Data Analysis</i>)
ASDID –	Auburn Soybean Disease Image Dataset
AUC –	Área sob a curva (<i>Area Under the Curve</i>)
CC0 –	Creative Commons Zero
CSV –	Valores separados por vírgula (<i>Comma-Separated Values</i>)
DL –	Aprendizado Profundo (<i>Deep Learning</i>)
FN –	Falsos negativos
FNR –	Taxa de falsos negativos (<i>False Negative Rate</i>)
FP –	Falsos positivos
FPR –	Taxa de falsos positivos (<i>False Positive Rate</i>)
IA –	Inteligência Artificial
IBGE –	Instituto Brasileiro de Geografia e Estatística
IQR –	Intervalo interquartil (<i>Interquartile Range</i>)
$\LaTeX$ –	Linguagem de preparação de textos científicos (<i>Lamport TeX</i>)
ML –	Aprendizado de Máquina (<i>Machine Learning</i>)
ResNet –	Rede Neural Residual (<i>Residual Network</i>)
RGB –	Canais de cor vermelho, verde e azul (<i>Red, Green, Blue</i>)
RNA –	Rede Neural Artificial
RNC –	Rede Neural Convolutacional (<i>Convolutional Neural Network</i>)
ROC –	Curva Característica de Operação do Receptor (<i>Receiver Operating Characteristic</i>)

TL –	Aprendizado por Transferência (<i>Transfer Learning</i>)
TPR –	Taxa de verdadeiros positivos (<i>True Positive Rate</i>)
USP –	Universidade de São Paulo
USPSC –	Campus da Universidade de São Paulo em São Carlos
VANT –	Veículo Aéreo Não Tripulado
VC –	Visão Computacional
VN –	Verdadeiros negativos
VP –	Verdadeiros positivos

SUMÁRIO

1	INTRODUÇÃO	23
1.1	Justificativa e Motivação	23
1.2	Questões de Pesquisa e Objetivos	24
1.2.1	Objetivo Geral	24
1.2.2	Objetivos Específicos	24
1.3	Declaração sobre uso de IA em apoio ao processo de desenvolvimento e escrita	25
2	FUNDAMENTOS DE IA E BIG DATA	27
2.1	Inteligência Artificial e Aprendizado de Máquina na Agricultura de Precisão	27
2.2	Redes Neurais Artificiais (RNA) e RNC	27
2.3	Big Data no Monitoramento Agrícola	28
2.4	Sensoriamento Remoto e Imagens Agrícolas	28
2.5	Bases Teóricas do Pipeline Experimental	29
2.5.1	A Arquitetura ResNet-50 e Conexões Residuais	29
2.5.2	Estratégias de Otimização para Modelos Pré-treinados	29
2.5.3	Aumento de Dados para Generalização do Modelo	30
2.5.4	Métricas de Avaliação para Problemas de Classificação	30
2.5.4.1	Acurácia e Matriz de Confusão	30
2.5.4.2	Precisão, Revocação e F1-Score	31
2.5.4.3	Coeficiente Kappa de Cohen	31
2.5.4.4	Curva Característica de Operação do Receptor (ROC) e Área sob a Curva (AUC)	31
2.5.4.5	Análise de Calibração e Confiança do Modelo	31
3	METODOLOGIA E DESENVOLVIMENTO EXPERIMENTAL	33
3.1	Introdução da Metodologia	33
3.2	Base Empírica e Conjunto de Dados	33
3.3	Ambiente de Desenvolvimento e Ferramentas	34
3.4	Análise de Procedimentos Metodológicos	34
3.4.1	Fase 1: Análise Exploratória e Preparação dos Dados	34
3.4.2	Fase 2: Pré-processamento e Estratificação dos Dados	37
3.4.3	Fase 3: Modelagem via Aprendizagem por Transferência	39
3.4.4	Fase 4: Otimização do Modelo via Ajuste Fino	40
3.4.5	Fase 5: Avaliação Final do Modelo	41

4	AVALIAÇÃO EXPERIMENTAL	49
4.1	Performance Geral do Modelo Final	49
4.2	Análise de Desempenho por Classe	49
4.3	Análise Crítica dos Erros e do Comportamento do Modelo	50
4.4	Síntese da Avaliação e Implicações	50
5	CONCLUSÕES	53
5.1	Resposta ao Objetivo Geral	53
5.2	Síntese da Trajetória Metodológica e Resultados Consolidados	53
5.3	Análise Crítica da Proposta e Implicações	53
5.4	Limitações e Proposições para Trabalhos Futuros	54
5.5	Considerações Finais	55
	REFERÊNCIAS	57

1 INTRODUÇÃO

No contexto da agricultura de larga escala, a detecção tardia de estresses bióticos e abióticos representa uma das principais causas de perdas produtivas e de ineficiência no uso de insumos. A manifestação de doenças e a ocorrência de desequilíbrios nutricionais são fatores que comprometem diretamente o potencial produtivo da lavoura (Ito, 2013), tornando o monitoramento contínuo uma prática indispensável para mitigar perdas e otimizar o uso de insumos (Junior, 2024). Contudo, o paradigma convencional de monitoramento fitossanitário, fundamentado na inspeção visual por amostragem e em análises laboratoriais, impõe barreiras críticas de escala e agilidade (ARAUJO, 2023). Essa abordagem tradicional sofre de duas limitações centrais. A primeira é a latência diagnóstica: o intervalo de tempo entre a coleta de amostras em campo e a confirmação laboratorial de um patógeno representa uma janela de oportunidade para a proliferação da doença, reduzindo a eficácia das medidas corretivas. A segunda é a inviabilidade de escala: a dependência de inspeções manuais torna a amostragem pouco representativa em grandes áreas, resultando em decisões de manejo baseadas em dados parciais, o que eleva os custos operacionais e compromete a sustentabilidade da produção (Santi *et al.*, 2014). Para superar as barreiras de latência e escala, a Inteligência Artificial (IA) e a Visão Computacional (VC) emergem como um novo paradigma para o monitoramento agrícola. Por meio da análise automatizada de imagens digitais, capturadas por sensores em campo ou por Veículos Aéreos Não Tripulados (VANT) (Jorge; Inamasu, 2013), é possível desenvolver sistemas de diagnóstico que operam em tempo próximo do real e com cobertura exponencialmente superior à inspeção manual. Nesse contexto, as Redes Neurais Convolucionais (RNC) — uma classe de modelos de Aprendizado de Máquina (ML) — representam o estado da arte para o reconhecimento de padrões visuais complexos (Das *et al.*, 2024). A capacidade intrínseca das RNC de aprender a identificar, a partir dos dados, variações sutis de coloração, textura e morfologia foliar as torna uma ferramenta ideal para a detecção de sintomas associados a doenças e a desequilíbrios nutricionais (Costa *et al.*, 2023), oferecendo um caminho para diagnósticos mais ágeis, objetivos e escaláveis.

1.1 Justificativa e Motivação

A relevância desta pesquisa transcende o avanço tecnológico, ancorando-se em impactos econômicos e ambientais diretos para o agronegócio. A prática corrente de aplicar defensivos agrícolas de forma preventiva ou em área total como contramedida para diagnósticos imprecisos eleva os custos de produção e pressiona as margens de lucro do produtor. Adicionalmente, esta abordagem resulta em consequências ambientais severas, como a contaminação do solo e de corpos d'água e o declínio de populações de polinizadores,

essenciais à biodiversidade (Pinheiro; Freitas, 2010).

O emprego estratégico da IA oferece um caminho para um manejo mais racional e sustentável. Ao possibilitar um diagnóstico fitossanitário rápido e localizado, a tecnologia permite a aplicação de insumos de forma direcionada, restrita às áreas que de fato necessitam de intervenção. Essa otimização se traduz em um duplo benefício: por um lado, a redução de custos operacionais e, por outro, a diminuição da carga química no ecossistema (Ferreira *et al.*, 2024). A motivação para esta pesquisa, portanto, alinha-se à necessidade de desenvolver ferramentas que capacitem o setor agrícola a enfrentar os desafios da produção de alimentos de forma mais resiliente, responsável e competitiva (Ferreira, 2025).

1.2 Questões de Pesquisa e Objetivos

Diante do contexto em que os métodos tradicionais de monitoramento impõem uma lacuna de agilidade e escala, resultando em decisões de manejo imprecisa (Santi *et al.*, 2014) e na intensificação do uso de defensivos (Ferreira *et al.*, 2024), surge a necessidade de um direcionador tecnológico. Este trabalho se propõe a investigar como uma arquitetura de RNC pode ser empregada para superar essas limitações.

1.2.1 Objetivo Geral

Este trabalho tem como objetivo geral desenvolver e validar um modelo de VC, baseado em RNC e Aprendizagem por Transferência (TL), para a identificação automática de um conjunto de doenças e estresses nutricionais em folhas de soja a partir de imagens digitais.

1.2.2 Objetivos Específicos

Para alcançar o objetivo geral, serão seguidas as seguintes etapas específicas:

- Realizar a coleta e o pré-processamento de um conjunto de dados de imagens, utilizando como base o repositório público Auburn Soybean Disease Image Dataset (ASDID);
- Desenvolver e otimizar uma arquitetura de RNC, por meio de TL, para a classificação dos estresses visuais identificados nas folhas de soja;
- Avaliar rigorosamente a *performance* do modelo final sobre um conjunto de dados de teste independente, utilizando métricas de classificação consolidadas na literatura.

1.3 Declaração sobre uso de IA em apoio ao processo de desenvolvimento e escrita

No desenvolvimento deste trabalho, o autor fez uso de ferramentas de IA generativa para correção de código e auxílio na escrita, sendo que este assume total responsabilidade pelo conteúdo publicado. As ferramentas utilizadas foram: Gemini, DeepSeek e ChatGPT.

2 FUNDAMENTOS DE IA E BIG DATA

2.1 Inteligência Artificial e Aprendizado de Máquina na Agricultura de Precisão

A Agricultura de Precisão é um paradigma de gestão agrícola que utiliza um conjunto de tecnologias para monitorar e otimizar a produção em campo, tratando a variabilidade espacial e temporal das lavouras (McBratney *et al.*, 2005; Mulla, 2013). A materialização deste conceito depende da capacidade de analisar grandes volumes de dados coletados por sensores, drones e satélites. Nesse contexto, a IA e o ML emergem como as ferramentas computacionais essenciais para transformar esses dados brutos em informações valiosas e acionáveis, permitindo um monitoramento mais eficiente e proativo (Saraiva *et al.*, 2024). Um marco disruptivo dentro do ML foi o advento do Aprendizado Profundo (DL), que automatizou a etapa de extração de características por meio de modelos com múltiplas camadas de representação (Krizhevsky; Sutskever; Hinton, 2012; LeCun; Bengio; Hinton, 2015). Essa capacidade se mostrou particularmente eficaz na análise de imagens, onde sistemas baseados em DL podem ser empregados, por exemplo, para a identificação automática de plantas daninhas, possibilitando um controle localizado e mais sustentável (Wessner; Frozza; Molz, 2024).

2.2 Redes Neurais Artificiais (RNA) e RNC

RNA são modelos computacionais inspirados na arquitetura do cérebro humano, projetados para aprender padrões a partir de dados (Martineli *et al.*, 1999). Dentre as diversas arquiteturas de RNA, as RNC representam um marco para tarefas de VC, sendo especialmente projetadas para processar dados com topologia de grade, como imagens digitais (Krizhevsky; Sutskever; Hinton, 2012). O diferencial das RNC reside no uso de camadas convolucionais, que aplicam filtros para detectar automaticamente características visuais em uma imagem. Nas camadas iniciais, esses filtros aprendem a identificar padrões simples, como bordas, cores e texturas. À medida que a informação avança pelas camadas mais profundas da rede, essas características são combinadas para formar padrões hierárquicos cada vez mais complexos. Essa capacidade de aprendizado de representações visuais consolidou as RNC como a abordagem padrão para a detecção de doenças em plantas, conforme demonstrado em trabalhos pioneiros que alcançaram alta acurácia na identificação de sintomas foliares (Mohanty; Hughes; Salathé, 2016), Ferentinos (2018) e Barbedo (2019). O sucesso dessas aplicações depende, contudo, da disponibilidade de grandes conjuntos de imagens rotuladas para treinar os modelos de forma eficaz (SILVA, 2024).

2.3 Big Data no Monitoramento Agrícola

O monitoramento agrícola moderno gera um fluxo contínuo e massivo de informações, caracterizando um cenário de Big Data, definido pela alta variedade, velocidade e volume dos dados coletados (Taurion, 2013). Essa gama de dados inclui desde telemetria de máquinas até registros históricos de produtividade e grandes repositórios de imagens de alta resolução capturadas por drones e sensores. O desafio imposto pelo Big Data não reside apenas no armazenamento, mas na análise para extrair informações valiosas que otimizem as operações em tempo real (Paino; Bearare, 2025). É nesse ponto que os modelos de ML, discutidos anteriormente, tornam-se indispensáveis, atuando como o propulsor analítico capaz de processar essa complexidade. Contudo, a materialização do potencial do Big Data no campo depende da superação de barreiras significativas, notadamente a deficiência de conectividade em zonas rurais, que dificulta a coleta e o processamento de dados em tempo real (Bernardocki; Murakami; Costa, 2023), e a necessidade de ferramentas com usabilidade e valor percebido claros para garantir a adoção pelos agricultores.

2.4 Sensoriamento Remoto e Imagens Agrícolas

O sensoriamento remoto é a tecnologia-chave para a aquisição de dados em larga escala na agricultura, permitindo o monitoramento da saúde das lavouras em diferentes resoluções espaciais e temporais (CASTRO, 2023). As duas principais plataformas para este fim são os satélites e os VANT, cuja escolha depende de um balanço técnico entre os objetivos do monitoramento. Para a análise de macroáreas, como talhões inteiros ou regiões, os satélites oferecem uma solução eficaz, com ampla área de cobertura e frequência de revisita periódica. Plataformas comerciais de alta resolução, como as constelações Pléiades e Planet Labs, fornecem dados detalhados para o acompanhamento geral da saúde das culturas e detecção de anomalias em larga escala (Berthier *et al.*, 2024; Jacobsen, 2022). O principal desafio desta abordagem é a resolução espacial, que geralmente não permite a identificação de sintomas em nível de planta individual, além da dependência de condições climáticas favoráveis (ausência de nuvens). Em contrapartida, para a análise de microáreas e a detecção de anomalias em escala fina, os VANT revolucionaram o monitoramento ao viabilizar a captura de imagens com resolução na casa dos centímetros (Nunes, 2023). Equipados com diversos sensores (Canais de cor vermelho, verde e azul (RGB), multiespectrais, termais), os VANT permitem a identificação de variabilidade dentro da lavoura que seria imperceptível por satélites (Pessi *et al.*, 2020). Essa alta resolução é ideal para tarefas como a detecção de sintomas foliares sutis. No entanto, essa abordagem apresenta seus próprios desafios, como a cobertura de área limitada por voo e a necessidade de maior planejamento operacional (Guebsi; Mami; Chokmani, 2024). A decisão entre satélite e VANT, portanto, não é de superioridade tecnológica, mas de adequação ao objetivo agrônomo. Enquanto o monitoramento de estresses em grandes

áreas pode ser realizado por satélites (Lukas *et al.*, 2016), a detecção precoce de sintomas visuais em folhas individuais - o foco deste trabalho - demanda a altíssima resolução tipicamente associada aos VANT ou a sensores de proximidade (Matese *et al.*, 2024; Raj *et al.*, 2024).

2.5 Bases Teóricas do Pipeline Experimental

As seções anteriores deste capítulo apresentaram o panorama geral que contextualiza esta pesquisa, abordando a aplicação da IA na agricultura de precisão e o panorama geral das RNC. Tendo estabelecido este alicerce conceitual, esta seção se aprofundará nas bases teóricas específicas que fundamentam cada componente do pipeline experimental desenvolvido. Serão detalhados a arquitetura de rede profunda selecionada, as estratégias de otimização empregadas e o conjunto de métricas utilizado para a avaliação rigorosa do desempenho do modelo.

2.5.1 A Arquitetura ResNet-50 e Conexões Residuais

A evolução das RNC para tarefas de VC demonstrou uma correlação direta entre a profundidade da rede e sua capacidade de aprender representações hierárquicas complexas. No entanto, o simples aumento do número de camadas introduziu o problema da degradação, em que redes mais profundas apresentavam um erro de treinamento maior devido à dificuldade em otimizar os parâmetros, um fenômeno associado ao desaparecimento do gradiente (He *et al.*, 2016). A família de arquiteturas de Redes Residuais (ResNet) surgiu como uma solução eficaz para este desafio. A inovação fundamental da ResNet é a introdução das conexões residuais (*skip connections*), que criam um “atalho” permitindo que a entrada de um bloco de camadas seja somada diretamente à sua saída. Este atalho cria um caminho alternativo para o fluxo do gradiente durante o treinamento, permitindo que ele se propague mais facilmente através de centenas de camadas sem se dissipar (He *et al.*, 2016). Em virtude dessas características — notadamente seu consolidado desempenho, a profundidade adequada para a complexidade de sintomas foliares e a estabilidade de treinamento proporcionada pelas conexões residuais — a arquitetura ResNet-50 foi selecionada como o modelo base para a construção do classificador, cuja implementação e treinamento são detalhados na Seção 3.4.3.

2.5.2 Estratégias de Otimização para Modelos Pré-treinados

O treinamento de redes neurais profundas a partir do zero demanda vastos conjuntos de dados e um custo computacional elevado. Para contornar essas limitações, a abordagem mais eficaz é a TL. Esta estratégia parte do princípio de que um modelo pré-treinado em uma tarefa em larga escala já aprendeu a reconhecer um rico repertório de características visuais genéricas (Pan; Yang, 2009). Na primeira etapa desta estratégia, o modelo pré-treinado é

utilizado como um extrator de características fixo, onde as camadas convolucionais são “congeladas” e apenas uma nova camada de classificação final é treinada. Posteriormente, a otimização pode ser aprofundada por meio do ajuste fino (*fine-tuning*), no qual as camadas convolucionais são “descongeladas” e toda a rede é treinada com uma taxa de aprendizado significativamente mais baixa, para refinar o conhecimento genérico e adaptá-lo aos padrões específicos do novo domínio de dados (Pan; Yang, 2009). Esta abordagem de otimização em duas fases constitui o fundamento metodológico da estratégia de treinamento a ser adotada neste trabalho, cujos resultados e implementação são detalhados nas Seções 3.4.3 e 3.4.4.

2.5.3 Aumento de Dados para Generalização do Modelo

Um dos maiores desafios no treinamento de redes neurais é o sobreajuste (*overfitting*). Para mitigar este risco, a técnica de Aumento de Dados (*Data Augmentation*) é um procedimento metodológico essencial (Shorten; Khoshgoftaar, 2019). Esta técnica consiste em expandir artificialmente o conjunto de dados de treinamento por meio da aplicação de transformações aleatórias, como rotações, recortes e inversões. Neste trabalho, foi empregada a abordagem de Aumento de Dados *on-the-fly*, que aplica estas transformações em tempo real na memória, criando um conjunto de treinamento virtualmente infinito e maximizando a variabilidade à qual o modelo é exposto (Shorten; Khoshgoftaar, 2019). A aplicação desta técnica foi um componente crítico para a regularização do modelo e para o aprimoramento de sua capacidade de generalização, sendo parte integral do pipeline de transformação do conjunto de treinamento, conforme detalhado na Seção 3.4.3.

2.5.4 Métricas de Avaliação para Problemas de Classificação

A avaliação de um modelo de classificação exige uma análise multifacetada. Para este fim, foi empregado um conjunto de métricas consolidadas na literatura.

2.5.4.1 Acurácia e Matriz de Confusão

A Acurácia é a métrica mais intuitiva para a avaliação de um modelo de classificação. Ela é definida como a proporção de predições corretas sobre o número total de amostras avaliadas. Contudo, a acurácia pode ser uma métrica enganadora em cenários com desbalanceamento de classes, onde um modelo trivial pode alcançar um valor alto simplesmente ao prever a classe majoritária (Provost; Fawcett, 2013).

Para superar essa limitação e obter um diagnóstico mais granular dos padrões de erro, utiliza-se a Matriz de Confusão. Esta matriz é uma tabela que contrapõe as classes preditas pelo modelo com as classes verdadeiras, permitindo a visualização direta dos Verdadeiros Positivos (VP), Falsos Positivos (FP), Verdadeiros Negativos (VN) e Falsos Negativos (FN) (Provost; Fawcett, 2013).

2.5.4.2 Precisão, Revocação e F1-Score

A partir da Matriz de Confusão, são derivadas métricas mais específicas. A Precisão ($VP / (VP + FP)$) mede a proporção de predições positivas que estavam corretas. A Revocação ($VP / (VP + FN)$), ou Sensibilidade, mede a proporção de amostras positivas reais que foram corretamente identificadas. O F1-Score é a média harmônica da precisão e da revocação, fornecendo uma avaliação única e robusta do desempenho por classe (Rijsbergen, 1979).

2.5.4.3 Coeficiente Kappa de Cohen

Para uma avaliação estatisticamente mais robusta, utiliza-se o Coeficiente Kappa de Cohen (κ). Esta métrica avalia o grau de concordância entre o modelo e os rótulos verdadeiros, corrigindo a concordância que seria esperada por mera casualidade, sendo particularmente útil em cenários com classes desbalanceadas (Cohen, 1960).

2.5.4.4 Curva Característica de Operação do Receptor (ROC) e Área sob a Curva (AUC)

Para uma avaliação do poder de discriminação de um classificador, utiliza-se a Curva ROC. Ela plota a Taxa de Verdadeiros Positivos (TPR) contra a Taxa de Falsos Positivos em diversos limiares de classificação. Para sumarizar a curva em um único valor, calcula-se a AUC. Uma AUC de 1.0 representa um classificador perfeito, enquanto 0.5 representa um desempenho aleatório (Fawcett, 2005).

2.5.4.5 Análise de Calibração e Confiança do Modelo

Além de avaliar a *performance* de um modelo com base em seus acertos e erros, é fundamental analisar a Confiança associada às suas predições. Em redes neurais para classificação, a Confiança é tipicamente representada pela probabilidade máxima na saída da camada *softmax*. Idealmente, essa probabilidade deveria refletir a probabilidade real de a predição estar correta, uma propriedade conhecida como calibração.

Um modelo bem calibrado é aquele que é “honesto” sobre sua própria incerteza: ele atribui alta confiança a predições que provavelmente estão corretas e, crucialmente, baixa confiança a predições que provavelmente estão incorretas. Modelos modernos de aprendizado profundo, apesar de sua alta acurácia, podem paradoxalmente tender a ser mal calibrados, exibindo um excesso de confiança (*overconfidence*) mesmo em suas predições errôneas (Guo *et al.*, 2017).

A análise de calibração, além da avaliação acadêmica, é de suma importância para a viabilidade e a segurança de sistemas de diagnóstico automatizado em aplicações de campo. A Confiança do modelo, quando devidamente calibrada, funciona como um metadado crucial, permitindo a implementação de protocolos de ação dinâmicos. Um sistema que não apenas fornece um diagnóstico, mas também quantifica sua própria certeza,

é intrinsecamente mais robusto e confiável. Esta capacidade de diferenciar predições de alta segurança daquelas que demandam atenção adicional é o que habilita a transição de um classificador experimental para uma ferramenta de apoio à decisão operacionalmente útil e segura. A investigação desta propriedade será, portanto, um componente essencial da avaliação final do modelo, conforme discutido na Seção 3.4.5.

3 METODOLOGIA E DESENVOLVIMENTO EXPERIMENTAL

3.1 Introdução da Metodologia

A metodologia adotada neste trabalho foi estruturada de forma a garantir rigor científico e alinhamento às melhores práticas em VC aplicada à agricultura de precisão. O estudo foi conduzido com base em um *pipeline* experimental sequencial, organizado em cinco fases interdependentes, projetado para assegurar reprodutibilidade, rastreabilidade e robustez científica. O fluxo foi desenvolvido para documentar cada decisão técnica, fundamentando as escolhas em evidências quantitativas e qualitativas obtidas ao longo do processo. Partindo de uma análise exploratória aprofundada do conjunto de dados, o percurso avança por etapas sistemáticas de curadoria, pré-processamento e modelagem, culminando na avaliação final do modelo em dados não vistos em treinamento.

3.2 Base Empírica e Conjunto de Dados

A fundação empírica do estudo foi constituída pelo conjunto de dados ASDID, um repositório público composto por 9.981 imagens de folhas de soja. A seleção deste *dataset* foi justificada por seu alinhamento temático com o escopo da pesquisa; pela robustez conferida pela heterogeneidade das amostras, capturadas em condições de campo com múltiplos dispositivos (câmera DSLR e smartphone); e pela acessibilidade garantida por sua licença Creative Commons Zero (CC0) 1.0. O conjunto de dados abrange oito categorias, sendo uma de folhas saudáveis e sete representativas de estresses bióticos (doenças) e abióticos (deficiência nutricional), conforme detalhado na Tabela 1.

Tabela 1 – Categorias de estresse biótico e abiótico do Conjunto de Dados ASDID

Categoria
1. Saudável
2. Crestamento Bacteriano (Bacterial blight)
3. Crestamento Foliar por Cercosporiose (Cercospora leaf blight)
4. Míldio (Downy mildew)
5. Mancha Foliar Olho-de-Rã (Frogeye leaf spot)
6. Ferrugem da Soja (Soybean rust)
7. Mancha-Alvo (Target spot)
8. Deficiência de Potássio (Potassium deficiency)

Fonte: Autor (2025).

3.3 Ambiente de Desenvolvimento e Ferramentas

O desenvolvimento experimental foi conduzido integralmente no ambiente de nuvem Google Colaboratory (SOUZA, 2025). A base de ferramentas foi constituída pela linguagem Python e um ecossistema de bibliotecas especializadas, com destaque para: `PyTorch` e `torchvision` para a construção e o treinamento dos modelos de aprendizado profundo; `pandas` e `numpy` para a manipulação de dados e engenharia de atributos; `matplotlib` e `seaborn` para a visualização gráfica; `scikit-learn` para a divisão estratificada dos dados e para o cálculo de métricas de avaliação; e as bibliotecas `pathlib` e `shutil` para a manipulação do sistema de arquivos. A reprodutibilidade científica do estudo foi assegurada por dois procedimentos metodológicos críticos. Inicialmente, uma semente de aleatoriedade (`seed=42`) foi fixada para todas as bibliotecas com componentes estocásticos, garantindo que os resultados fossem determinísticos e replicáveis. Adicionalmente, foi gerado um arquivo de dependências (`requirements.txt`), que documenta as versões exatas de todas as bibliotecas utilizadas, permitindo a recriação precisa do ambiente de software.

3.4 Análise de Procedimentos Metodológicos

O desenvolvimento do modelo de classificação foi conduzido através das cinco fases sequenciais previamente delineadas. Esta seção detalha cada uma dessas etapas, iniciando pela AED.

3.4.1 Fase 1: Análise Exploratória e Preparação dos Dados

A fase inicial da metodologia foi dedicada à AED, um procedimento sistemático de investigação para caracterizar o *dataset*, validar sua integridade e extrair insights que fundamentassem as decisões de pré-processamento e modelagem. O primeiro passo consistiu na curadoria do conjunto de dados. Por meio de um script, foi realizada uma contagem programática que iterou sobre os diretórios, quantificando apenas as imagens válidas e ignorando artefatos não pertinentes. Este processo foi crucial para estabelecer o escopo numérico exato do estudo, consolidando o universo de trabalho em 9.667 imagens. A distribuição destas amostras, detalhada na Tabela 2, revelou um desbalanceamento natural entre as categorias, com classes majoritárias (e.g., *healthy*) sendo mais de três vezes mais representadas que classes minoritárias (e.g., *bacterial blight*). Este diagnóstico inicial foi fundamental para justificar a adoção de técnicas de divisão estratificada e amostragem ponderada em etapas posteriores.


Na sequência, foi realizada uma inspeção visual qualitativa para validar a correspondência semântica entre o conteúdo das imagens e seus respectivos rótulos, conforme ilustrado na Figura 1. Este procedimento de sanidade confirmou a consistência geral do *dataset* e permitiu observar a alta variabilidade intra-classe, como diferentes condições de iluminação, ângulos de captura e fundos.

Tabela 2 – Distribuição Final de Imagens por Categoria após Curadoria

Categoria	Quantidade	Percentual (%)
Healthy	1632	16.88
Soybean rust	1627	16.83
Cercospora leaf blight	1617	16.73
Frogeye	1540	15.93
Target spot	1081	11.18
Potassium deficiency	1034	10.70
Downy mildew	652	6.74
Bacterial blight	484	5.01

Fonte: Autor (2025).

Figura 1 – Amostras visuais das categorias do conjunto de dados ASDID



Fonte: Autor (2025).

Para aprofundar a caracterização, foi executado um processo de extração programática de metadados, no qual cada imagem foi analisada para extrair atributos técnicos como dimensões (largura e altura) e modo de cor. Os dados resultantes foram estruturados e persistidos em um arquivo de valores separados por vírgula (CSV), transformando o conjunto de imagens em uma base de dados analítica. A partir desta base, foram criadas, por meio de engenharia de atributos, as variáveis Área (largura x altura) e Proporção (razão de aspecto). Uma análise estatística descritiva destes metadados (Tabela 3) quantificou a tendência central e a dispersão das características físicas das imagens, confirmando a predominância de imagens de alta resolução, mas também a presença de uma variação dimensional significativa.

A culminação da AED foi a análise visual das distribuições destes metadados. Gráficos de boxplot (Figura 2), histogramas (Figura 3) e diagramas de dispersão (Figuras 4


Tabela 3 – Resumo Estatístico dos Atributos Numéricos das Imagens

Estatística	Largura	Altura	Área	Proporção	Modo de Cor
count	9667.00	9667.00	9667.00	9667.00	RGB (9667)
mean	5083.29	3478.96	178770886.86	1.45	–
std	670.09	291.39	3551130.62	0.08	–
min	194.00	259.00	50246.00	0.70	–
25%	4000.00	3000.00	12000000.00	1.33	–
50%	5472.00	3648.00	19961856.00	1.50	–
75%	5472.00	3648.00	19961856.00	1.50	–
max	5472.00	3648.00	19961856.00	1.50	–

Fonte: Autor (2025).

e 5) foram gerados para investigar padrões e identificar outliers. A análise gráfica confirmou a heterogeneidade das resoluções e, para complementar esta observação, uma quantificação numérica de outliers foi realizada utilizando o método do Intervalo Interquartil (IQR), cujos resultados estão sumarizados na Tabela 4.


Figura 2 – Boxplot da Área por Categoria



Fonte: Autor (2025).


Em síntese, os achados desta fase informaram diretamente as seguintes decisões metodológicas que definiram a etapa de pré-processamento: (i) a necessidade de uma etapa de limpeza para remover imagens de baixa resolução; (ii) a obrigatoriedade de padronizar as dimensões das imagens para a entrada na rede neural; e (iii) a adoção de estratégias

Figura 3 – Histogramas da Distribuição Geral de Área e Proporção



Fonte: Autor (2025).

Figura 4 – Gráficos de dispersão das resoluções por categoria com eixos globais (fixos).




Fonte: Autor (2025).

específicas para mitigar os efeitos do desbalanceamento de classes durante o treinamento do modelo.

3.4.2 Fase 2: Pré-processamento e Estratificação dos Dados

Após a fase exploratória, a metodologia prosseguiu com a preparação do conjunto de dados para a modelagem. Este processo compreendeu três procedimentos sequenciais: o saneamento das amostras, o particionamento estratificado e a organização física dos arquivos. O procedimento inicial consistiu na limpeza do *dataset*. Com base nos achados da análise anterior, que revelou a presença de imagens com dimensões muito reduzidas, foi aplicado um critério de filtragem por limiar absoluto. Todas as imagens com área total inferior a 500.000 pixels foram programaticamente identificadas e removidas. Este procedimento de curadoria resultou na exclusão de 3 amostras, refinando o conjunto de

Figura 5 – Gráficos de dispersão das resoluções por categoria com eixos locais (dinâmicos).



Fonte: Autor (2025).

Tabela 4 – Contagem de outliers superiores por categoria e atributo (método IQR)

Categoria	Outliers em Área	Outliers em Proporção
Bacterial blight	0	0
Cercospora leaf blight	0	0
Downy mildew	0	0
Frogeye	0	0
Healthy	0	0
Potassium deficiency	0	0
Soybean rust	0	0
Target spot	0	0

Fonte: Autor (2025).

Nota: Nenhum outlier superior foi identificado pelo método IQR (limiar = $Q3 + 1,5 \cdot IQR$) para as métricas *Área* e *Proporção* em nenhuma categoria.

dados para um total de 9.664 imagens que seguiram para as etapas posteriores. Após a filtragem, o conjunto de dados foi particionado em três subconjuntos: treinamento (70%), validação (15%) e teste (15%). Para garantir que a distribuição de classes original, diagnosticada como desbalanceada na Fase 1, fosse preservada em cada subconjunto, foi empregado o método de divisão estratificada. Esta abordagem é metodologicamente crucial para prevenir que categorias minoritárias fossem sub-representadas em alguma das partições, o que invalidaria a avaliação do modelo. A etapa final do pré-processamento foi a materialização desta divisão lógica em uma estrutura de diretórios física. As imagens de cada subconjunto foram copiadas para uma estrutura hierárquica (train/, validation/, test/), um formato padrão que otimiza o carregamento de dados em frameworks de aprendizado profundo. Como ponto de controle de qualidade, foi realizada uma verificação programática final para auditar o processo, confirmando que a contagem de arquivos físicos

correspondia exatamente à divisão lógica planejada, conforme detalhado na Tabela 5.

Tabela 5 – Distribuição Estratificada das Imagens por Categoria e Subconjunto

Categoria	Treinamento (70%)		Validação (15%)		Teste (15%)	
	Qtd.	%	Qtd.	%	Qtd.	%
Healthy	1100	16.9	246	16.9	246	16.9
Soybean rust	1137	16.8	245	16.8	245	16.8
Cercospora leaf blight	1129	16.7	244	16.8	244	16.7
Frogeye	1075	15.9	232	15.9	233	15.9
Target spot	757	11.2	162	11.2	162	11.2
Potassium deficiency	725	10.7	155	10.7	154	10.7
Downy mildew	452	6.7	98	6.8	102	6.8
Bacterial blight	329	5.0	72	5.0	83	5.0
Total	6764	100	1450	100	1450	100

Fonte: Autor (2025). Resultados da divisão estratificada (train/validation/test) preservando as proporções de cada categoria.

3.4.3 Fase 3: Modelagem via Aprendizagem por Transferência

Com o conjunto de dados preparado, a terceira fase do *pipeline* foi dedicada à construção e ao treinamento do modelo de referência (*baseline*). A escolha da arquitetura ResNet-50 foi fundamentada em seu consolidado desempenho em tarefas de classificação de imagens e em seu design robusto para DL. Com 50 camadas, o modelo oferece um equilíbrio eficaz entre profundidade — essencial para a extração de características visuais complexas, como os sintomas de doenças foliares — e eficiência computacional. Sua principal vantagem metodológica reside nas conexões residuais, que mitigam o problema da degradação de gradiente em redes profundas, garantindo um treinamento mais estável. Por ser amplamente utilizada como um *benchmark* na literatura, a ResNet-50 constitui um *baseline* forte e confiável, ideal para a aplicação da estratégia de TL, que foi a estratégia metodológica adotada neste trabalho. A arquitetura selecionada foi a ResNet-50, carregada com pesos pré-treinados no *dataset* ImageNet. Para adaptar o modelo ao problema em questão, os pesos de todas as camadas convolucionais (o extrator de características) foram “congelados”, e a camada de classificação final foi substituída por uma nova camada linear, dimensionada para as oito categorias do estudo. Desta forma, apenas os parâmetros desta nova camada foram configurados como treináveis. Para a entrada de dados no modelo, foram definidos dois *pipelines* distintos de transformação. O primeiro, aplicado aos conjuntos de validação e teste, consistiu em um pré-processamento determinístico para garantir uma avaliação consistente, incluindo redimensionamento (*Resize*), recorte central (*CenterCrop*) e normalização com os parâmetros do ImageNet. O segundo *pipeline*, aplicado exclusivamente ao conjunto de treinamento, empregou a técnica de Aumento de Dados *on-the-fly*. Este processo introduziu variações estocásticas em cada imagem a cada época

— como recortes com redimensionamento (*RandomResizedCrop*), inversões horizontais (*RandomHorizontalFlip*) e rotações (*RandomRotation*) — com o objetivo de expandir artificialmente a diversidade dos dados e melhorar a capacidade de generalização do modelo. Subsequentemente, foram construídos os carregadores de dados (*DataLoaders*) com *batch size* de 32. Para mitigar o desbalanceamento de classes, o carregador de treinamento foi configurado com um amostrador ponderado (*WeightedRandomSampler*), que selecionou com maior frequência as imagens das classes minoritárias para garantir uma exposição equitativa durante o treinamento.


O processo de otimização foi orientado por hiperparâmetros canônicos para tarefas de TL. A função de perda Entropia Cruzada (*Cross Entropy Loss*) foi selecionada como critério. O otimizador Adam, uma escolha padrão por sua eficiência adaptativa, foi instanciado para atualizar exclusivamente os pesos da nova camada classificadora, com uma taxa de aprendizagem inicial de 1×10^{-3} , valor empiricamente consolidado para esta etapa de treinamento. Adicionalmente, foi implementado um agendador de taxa de aprendizagem (*StepLR*) para reduzir a taxa de aprendizagem por um fator de `gamma=0.1` a cada 7 épocas (`step size=7`), visando a uma convergência mais estável e refinada.

O ciclo de treinamento foi executado por 25 épocas, com um mecanismo de *checkpointing* duplo para garantir a resiliência e a preservação do melhor resultado. Conforme as curvas de aprendizagem apresentadas na Figura 6, o modelo alcançou sua *performance* máxima no conjunto de validação na décima quarta época, atingindo uma acurácia de 88,55%. Este resultado consolidou o desempenho do modelo de referência e serviu como *baseline* para a fase subsequente de ajuste fino.

3.4.4 Fase 4: Otimização do Modelo via Ajuste Fino

A quarta fase da metodologia foi dedicada à otimização do modelo de referência por meio de Ajuste Fino. O objetivo desta etapa foi refinar os pesos de todas as camadas da rede, incluindo os extratores de características convolucionais, para adaptá-los de forma mais específica ao domínio visual das doenças foliares da soja. Como procedimento inicial, foi realizado um *backup* do melhor modelo obtido na fase de TL. Esta ação metodológica foi crucial para preservar o artefato de *baseline* (acurácia de 88,55%) e permitir uma análise comparativa direta do ganho de *performance* obtido com o ajuste fino. O modelo foi então reconfigurado para o novo ciclo de treinamento. Inicialmente, todos os parâmetros da rede, que antes estavam congelados, foram “descongelados”, permitindo que os gradientes fossem calculados para todas as camadas (*requires grad=True*). Em seguida, os hiperparâmetros foram redefinidos: um novo otimizador Adam foi instanciado, agora atuando sobre todos os parâmetros, com uma taxa de aprendizagem significativamente reduzida para 1×10^{-4} . Esta redução drástica foi uma decisão metodológica deliberada para garantir que os ajustes nos pesos pré-treinados fossem sutis, refinando o conhecimento existente em vez de

Figura 6 – Curvas de Aprendizagem da Fase de TL.



Métricas Extraídas da Melhor Performance:

- **Época de Pico de Desempenho:** 14
- **Acurácia Máxima de Validação:** 0.8855
- **Perda de Validação Correspondente:** 0.3829
- **Acurácia de Treinamento (na Época de Pico):** 0.9196
- **Gap de Generalização (Acurácia Treino - Val):** 0.0341


Fonte: Autor (2025).

desestabilizá-lo. Um novo agendador *StepLR* também foi configurado, com os parâmetros `step size=5` e `gamma=0.1`. O segundo ciclo de treinamento foi executado por 15 épocas, com os *checkpoints* sendo salvos em arquivos distintos para garantir a segregação dos resultados desta fase. O processo de ajuste fino validou empiricamente a hipótese de otimização, resultando em um ganho de performance substancial e elevando a acurácia máxima de validação para 98,34%, alcançada na décima terceira época. A análise das curvas de aprendizagem desta fase (Figura 7) confirmou a convergência do modelo para um patamar de desempenho superior, com um comportamento de generalização robusto.

3.4.5 Fase 5: Avaliação Final do Modelo

A fase final do *pipeline* experimental consistiu na avaliação rigorosa e multifacetada do modelo otimizado sobre o conjunto de teste, composto por 1.450 imagens nunca

Figura 7 – Curvas de Aprendizado da Fase de ajuste fino




Métricas Extraídas da Melhor Performance:

- **Época de Pico de Desempenho:** 13
- **Acurácia Máxima de Validação:** 0.9834
- **Perda de Validação Correspondente:** 0.0621
- **Acurácia de Treinamento (na Época de Pico):** 0.9984
- **Gap de Generalização (Acurácia Treino - Val):** 0.0149

Fonte: Autor (2025).

vistas em treinamento. Como procedimento inicial, o modelo de melhor *performance* da fase de Ajuste Fino foi carregado e configurado para o modo de inferência (`.eval()`), garantindo um comportamento determinístico e a integridade da avaliação. A inferência foi então executada, coletando para cada amostra o rótulo verdadeiro, a predição e o vetor de probabilidades para a análise subsequente. A primeira métrica avaliada foi a acurácia global, que indicou que o modelo classificou corretamente 96,83% das amostras, demonstrando uma excelente capacidade de generalização para dados não vistos. Para uma análise mais granular dos padrões de acerto e erro, foi gerada a matriz de confusão normalizada (Figura 8). A avaliação foi aprofundada por um relatório de classificação detalhado (Tabela 6), que apresentou, para cada classe, as métricas de precisão, revocação (*recall*) e F1-Score, fundamentais para uma análise robusta em um cenário de classes desbalanceadas.

Figura 8 – Matriz de confusão normalizada por classe para o conjunto de teste. A diagonal principal representa a porcentagem de acertos para cada classe.



Fonte: Autor (2025).

Para contextos agronômicos, onde os custos de erro são assimétricos, foi realizada uma análise de custo de erro, quantificando as FPR e FNR para cada classe (Tabela 7). Para conferir um nível superior de rigor estatístico, foi calculado o Coeficiente Kappa de Cohen, que resultou em $\kappa = 0.9631$. Este valor, segundo a escala de Landis e Koch (1977), representa uma “Concordância Quase Perfeita” entre as previsões do modelo e os rótulos verdadeiros, corrigindo o efeito de acertos que poderiam ocorrer ao acaso.

A avaliação quantitativa foi complementada por diagnósticos avançados. Foi investigada a calibração do modelo (Figura 9), confirmando que ele não apenas acerta com alta confiança (média de 98,88%), mas também demonstra menor certeza ao cometer erros (média de 74,31%). Adicionalmente, uma análise qualitativa dos 46 erros de classificação (Figura 10) permitiu a formulação de hipóteses sobre as limitações do modelo, como a dificuldade em distinguir sintomas visuais sutis. Como avaliação final do poder de discriminação do classificador, foi realizada a análise da Curva ROC e da AUC. Os resultados (Figura 11 e Tabela 8) confirmaram a *performance* excepcional do modelo, que alcançou uma AUC média de 0.9995.

Tabela 6 – Relatório de classificação detalhado com as métricas de Precision, Recall e F1-Score por classe, e a acurácia geral do modelo.

Classe	Precision	Recall	F1-Score	Support
Bacterial Blight	0.91	0.96	0.93	73
Cercospora Leaf Blight	0.99	0.95	0.97	242
Downey Mildew	0.93	1.00	0.97	98
Frogeye	0.96	0.97	0.97	231
Healthy	0.99	0.93	0.96	245
Potassium Deficiency	0.99	1.00	0.99	155
Soybean Rust	0.96	0.97	0.96	244
Target Spot	0.97	1.00	0.98	162
Acurácia (Accuracy)			0.97	1450
Média Macro (Macro Avg)	0.96	0.97	0.97	1450
Média Ponderada (Weighted Avg)	0.97	0.97	0.97	1450

Fonte: Autor (2025).

Tabela 7 – Análise de Custo de Erro por Classe, com as respectivas Taxas de Falsos Positivos (FPR) e Falsos Negativos (FNR).


Classe	Falsos Positivos (FPR)	Falsos Negativos (FNR)
Bacterial Blight	0.51%	4.11%
Cercospora Leaf Blight	0.25%	4.96%
Downey Mildew	0.52%	0.00%
Frogeye	0.74%	2.60%
Healthy	0.25%	6.94%
Potassium Deficiency	0.15%	0.00%
Soybean Rust	0.83%	3.28%
Target Spot	0.39%	0.00%

Nota: Escala de Interpretação para o Coeficiente Kappa ($\kappa = 0,9631$), segundo Landis e Koch (1977).

Valor de Kappa	Interpretação
< 0.00	Concordância Pobre
0.00 - 0.20	Concordância Leve
0.21 - 0.40	Concordância Razoável
0.41 - 0.60	Concordância Moderada
0.61 - 0.80	Concordância Substancial
0.81 - 1.00	Concordância Quase Perfeita

Fonte: Autor (2025).

Figura 9 – Histograma de densidade para a distribuição de confiança do modelo. A distribuição para previsões corretas (verde) concentra-se em alta confiança, enquanto as incorretas (vermelho) apresentam menor confiança.



Análise da Confiança Média:

- **Confiança Média (Previsões Corretas):** 0.9888
- **Confiança Média (Previsões Incorretas):** 0.7431

Fonte: Autor (2025).

Tabela 8 – Área Sob a Curva (AUC) por Classe e Média Agregada no Conjunto de Teste. Valores mais próximos de 1.0 indicam maior poder de discriminação do modelo.

Classe / Média	Valor AUC
Bacterial Blight	0.9996
Cercospora Leaf Blight	0.9989
Downey Mildew	1.0000
Frogeye	0.9990
Healthy	0.9993
Potassium Deficiency	1.0000
Soybean Rust	0.9991
Target Spot	1.0000
Média Macro (Macro-Avg)	0.9995

Fonte: Autor (2025).

Figura 10 – Inspeção visual de uma amostra de erros de classificação

Rótulo Verdadeiro: soybean_rust
Predição do Modelo: frogeye



Rótulo Verdadeiro: healthy
Predição do Modelo: downey_mildew



Rótulo Verdadeiro: healthy
Predição do Modelo: soybean_rust



Rótulo Verdadeiro: soybean_rust
Predição do Modelo: bacterial_blight



Rótulo Verdadeiro: healthy
Predição do Modelo: cercospora_leaf_blight



Rótulo Verdadeiro: soybean_rust
Predição do Modelo: frogeye



Rótulo Verdadeiro: cercospora_leaf_blight
Predição do Modelo: frogeye



Rótulo Verdadeiro: cercospora_leaf_blight
Predição do Modelo: bacterial_blight




Rótulo Verdadeiro: cercospora_leaf_blight
Predição do Modelo: healthy



Rótulo Verdadeiro: cercospora_leaf_blight
Predição do Modelo: soybean_rust



Figura 11 – Curva Característica de Operação do Receptor (ROC) para o conjunto de teste. São exibidas as curvas para cada classe, bem como as de micro e macro-average, que indicam a performance agregada do modelo.



Fonte: Autor (2025).

4 AVALIAÇÃO EXPERIMENTAL

Este capítulo apresenta a avaliação de desempenho do modelo de classificação final, treinado e otimizado conforme a metodologia descrita no capítulo anterior. A análise foi conduzida sobre o conjunto de teste, composto por 1.450 imagens inéditas, para aferir a capacidade de generalização do modelo em dados não vistos. Os resultados são apresentados de forma sequencial, partindo de métricas de performance globais e avançando para análises granulares por classe e diagnósticos críticos dos padrões de erro.

4.1 Performance Geral do Modelo Final

A performance geral do modelo no conjunto de teste, composto por 1.450 imagens inéditas, validou a eficácia do pipeline experimental. O modelo alcançou uma acurácia global de 96,83%. Esta alta performance foi corroborada estatisticamente pelo Coeficiente Kappa de Cohen, que atingiu $\kappa = 0.9631$, indicando “Concordância Quase Perfeita” (Landis e Koch, 1977). Adicionalmente, o poder de discriminação do classificador foi confirmado pela AUC, que obteve uma média de 0.9995. Em conjunto, estas métricas consolidam a alta performance e a validade do modelo final.

4.2 Análise de Desempenho por Classe

Superada a avaliação da performance agregada, a análise foi aprofundada para investigar o desempenho do modelo em cada uma das oito classes do problema. Este diagnóstico granular é fundamental para verificar se a alta acurácia global não está mascarando uma performance deficiente em categorias minoritárias, validando a eficácia das estratégias de amostragem ponderada adotadas durante o treinamento. A principal ferramenta para esta análise foi a Matriz de Confusão, apresentada na Figura 8. A forte concentração de valores na diagonal principal da matriz indica um alto índice de acertos para todas as classes. A análise dos erros (valores fora da diagonal) revela que não houve um padrão de confusão sistemático entre duas classes específicas, sugerindo que o modelo aprendeu a distinguir as características visuais de cada categoria de forma eficaz.

Para uma quantificação precisa deste desempenho, o Relatório de Classificação (Tabela 6) detalhou as métricas de Precisão, Revocação e F1-Score para cada categoria. A análise do relatório confirma a robustez do modelo: mesmo as classes minoritárias, como *bacterial blight* e *downey mildew*, alcançaram um F1-Score superior a 0.95. Este resultado é particularmente relevante, pois demonstra que o modelo não desenvolveu um viés em favor das classes majoritárias, sendo capaz de identificar com alta precisão e alta revocação todas as categorias presentes no conjunto de teste.

4.3 Análise Crítica dos Erros e do Comportamento do Modelo

Para uma avaliação completa, é imperativo analisar não apenas os acertos, mas também a natureza e as implicações dos erros cometidos pelo modelo. Esta seção aprofunda a análise sob três perspectivas críticas: o custo assimétrico dos erros no contexto agrônomo, a calibração da confiança do modelo e uma inspeção qualitativa das falhas de classificação. Primeiramente, foi conduzida uma análise de custo de erro, quantificando as FPR e FNR para cada classe (Tabela 7). Os resultados indicam uma FPR consistentemente baixa em todas as categorias, o que significa que o modelo raramente gera “alarmes falsos”. No entanto, a análise da FNR, que mede a taxa de casos reais não detectados, revela nuances importantes. Uma FNR, ainda que baixa, é mais crítica do ponto de vista agrônomo, pois uma doença não diagnosticada (FN) pode levar à sua proliferação, acarretando custos de manejo e perdas de produtividade superiores aos de uma inspeção desnecessária (FP).

A avaliação prosseguiu com a análise da calibração do modelo, que investiga se a confiança de suas predições reflete a probabilidade real de acerto. A Figura 9 mostra que o modelo é, em geral, bem calibrado: a confiança média para as predições corretas foi de 98,88%, enquanto para as predições incorretas foi significativamente menor, de 74,31%. Este resultado indica um modelo robusto, que não apenas acerta com alta confiança, mas também demonstra menor certeza ao cometer erros. Contudo, a análise da distribuição revela que uma pequena fração dos erros ainda foi cometida com alta confiança, um fenômeno que representa uma limitação e um ponto para refinamentos futuros.

Finalmente, foi realizada uma análise qualitativa dos 46 erros de classificação por meio da inspeção visual de uma amostra das imagens incorretamente classificadas (Figura 10). Esta observação direta permitiu a formulação de hipóteses sobre as limitações do modelo, como a dificuldade em distinguir doenças com sintomas visuais muito sutis ou sobrepostos, ou em imagens com condições de iluminação desfavoráveis. Esta análise contextualiza os resultados numéricos, conectando as falhas do modelo às complexidades intrínsecas dos dados do mundo real.

4.4 Síntese da Avaliação e Implicações

A avaliação experimental multifacetada, detalhada nas seções anteriores, validou de forma robusta a eficácia do modelo desenvolvido. As análises confirmaram não apenas a alta performance global (Seção 4.1), mas também a robustez do classificador em nível de classe (Seção 4.2) e seu comportamento de calibração confiável (Seção 4.3), confirmando que o *pipeline* metodológico proposto resultou em um classificador de alto desempenho.

A análise granular demonstrou que a performance se manteve elevada mesmo para as classes minoritárias, evidenciando o sucesso da estratégia de amostragem ponderada e da técnica de ajuste fino na mitigação do viés de treinamento. A análise crítica dos

erros, por sua vez, contextualizou as limitações do modelo, associando as falhas a desafios inerentes à complexidade dos dados visuais agrícolas, como a sutileza dos sintomas em estágios iniciais.

Em suma, os resultados consolidam a hipótese de que a abordagem de duas fases — TL para estabelecer um *baseline* robusto, seguida de ajuste fino para especialização de domínio — é uma estratégia metodológica altamente eficaz para problemas de classificação de doenças em plantas. As métricas de desempenho alcançadas não apenas validam o modelo do ponto de vista técnico, mas também indicam seu forte potencial como uma ferramenta de apoio à decisão na agricultura de precisão, oferecendo um caminho para diagnósticos mais ágeis e precisos.

Esta discussão serve como alicerce para as conclusões finais e as proposições de trabalhos futuros, que serão detalhadas no capítulo subsequente.

5 CONCLUSÕES

Este capítulo final tem como propósito consolidar os resultados da pesquisa, conectar os achados experimentais aos objetivos propostos e discutir as implicações e contribuições do trabalho. A estrutura a seguir retoma a pergunta de pesquisa, sumariza a jornada metodológica e os resultados, oferece uma análise crítica da proposta e aponta direções para futuras investigações na área.

5.1 Resposta ao Objetivo Geral

Conclui-se, com base na robusta avaliação experimental apresentada no Capítulo 4, que este objetivo foi plenamente alcançado. A metodologia de duas fases, combinando TL e ajuste fino, resultou em um classificador final com uma Acurácia global de 96,83% em um conjunto de teste independente, validado por métricas estatísticas que atestam uma concordância “quase perfeita” ($\kappa = 0.9631$) e um poder de discriminação excepcional (AUC média = 0.9995). Estes resultados constituem a evidência empírica de que a abordagem proposta é altamente eficaz para o problema em questão.

5.2 Síntese da Trajetória Metodológica e Resultados Consolidados

O alcance do objetivo geral foi possibilitado por uma trajetória metodológica rigorosa, executada em um *pipeline* de cinco fases interdependentes. A primeira fase, de AED, foi crucial para a curadoria do *dataset* e para o diagnóstico de características como o desbalanceamento de classes, que balizaram as decisões subsequentes. A segunda fase, de Pré-processamento, transformou os dados brutos em um conjunto limpo, particionado de forma estratificada e organizado para o treinamento.

As fases de Modelagem constituíram o núcleo experimental do trabalho. A estratégia de TL estabeleceu um *baseline* robusto, cujo desempenho foi significativamente elevado na fase de ajuste fino, validando a importância de refinar os extratores de características para o domínio específico do problema. Finalmente, a fase de Avaliação Final submeteu o modelo otimizado a uma avaliação abrangente sob múltiplas métricas em um conjunto de dados não visto.

5.3 Análise Crítica da Proposta e Implicações

A validação de um modelo de DL com acurácia superior a 96% representa, por si só, um resultado técnico expressivo. No entanto, a contribuição deste trabalho reside não apenas na *performance* final, mas na análise crítica da metodologia empregada e nas suas implicações práticas para a agricultura de precisão.

A estratégia de duas fases, combinando TL e ajuste fino, provou ser fundamental. A primeira fase estabeleceu rapidamente um modelo funcional com desempenho considerável (88,55%), enquanto a segunda, por meio de um ajuste sutil dos pesos com uma taxa de aprendizagem reduzida, foi capaz de especializar a rede para as nuances visuais das doenças da soja, resultando em um ganho de quase 10 pontos percentuais na acurácia de validação. Isso corrobora a hipótese de que, mesmo para arquiteturas pré-treinadas em *datasets* genéricos, uma etapa de ajuste fino de domínio específico é crucial para alcançar o estado da arte em tarefas especializadas.

A análise crítica dos erros, embora poucos, revela as limitações inerentes à abordagem. A dificuldade do modelo em alguns casos de sintomas sutis ou sobrepostos indica que a classificação baseada apenas em imagens *RGB* possui um teto de *performance*. Isso sugere que a verdadeira fronteira para diagnósticos ainda mais precoces reside na exploração de dados multiespectrais ou hiperespectrais, capazes de capturar estresses bioquímicos antes da manifestação visual completa.

Do ponto de vista prático, as implicações deste trabalho são significativas. A demonstração de um classificador de alta Precisão e alta Revocação, validado por métricas robustas, fundamenta a viabilidade de ferramentas de apoio à decisão que podem oferecer diagnósticos fitossanitários em questão de segundos. Tais ferramentas têm o potencial de democratizar o acesso a diagnósticos rápidos, reduzir a dependência de análises laboratoriais demoradas e permitir intervenções de manejo mais ágeis e localizadas, resultando em otimização de insumos e maior sustentabilidade.

5.4 Limitações e Proposições para Trabalhos Futuros

Apesar dos resultados expressivos, este estudo possui limitações inerentes ao seu escopo que, por sua vez, delineiam oportunidades claras para futuras investigações. A principal limitação reside na base empírica: embora robusto, o trabalho foi desenvolvido sobre um único *dataset* público (ASDID), o que implica que a generalização do modelo para diferentes variedades de soja, condições edafoclimáticas e equipamentos de captura necessitaria de validação adicional. Ademais, a metodologia foi focada na classificação de sintomas visíveis em imagens RGB, não abordando a quantificação da severidade ou a detecção pré-sintomática.

Com base nestas limitações, propõem-se duas linhas de pesquisa futuras que representam a evolução natural deste trabalho:

Quantificação da Severidade de Doenças via Segmentação Semântica: o próximo passo lógico consiste em evoluir do diagnóstico de classificação (“o que é?”) para a quantificação da severidade (“qual o tamanho do dano?”). Para tal, propõe-se o desenvolvimento de um modelo baseado em arquiteturas de segmentação semântica, como a **U-Net**, treinado

sobre um *dataset* com anotações a nível de *pixel*. Um sistema com essa capacidade não apenas diagnosticaria a doença, mas também calcularia a porcentagem da área foliar afetada, fornecendo um indicador quantitativo crucial para decisões de manejo agrônomo.

Detecção Pré-Sintomática com Imagens Hiperespectrais: uma segunda e mais avançada linha de pesquisa seria a exploração da detecção pré-sintomática, ou “AI Forecasting”. Esta abordagem utilizaria dados de sensores hiperespectrais para identificar as assinaturas espectrais de estresse bioquímico nas plantas antes mesmo da manifestação de sintomas visíveis. A aplicação de arquiteturas especializadas, como Redes Convolucionais 3D ou **Transformers**, a estes cubos de dados teria o potencial de criar um sistema de alerta verdadeiramente precoce, representando uma mudança de paradigma do diagnóstico para o prognóstico fitossanitário.

Estas proposições demonstram que o presente trabalho não apenas cumpre seus objetivos, mas também serve como um alicerce sólido para uma linha de pesquisa de longo prazo e de alto impacto para a agricultura de precisão.

5.5 Considerações Finais

O presente trabalho demonstrou com sucesso a viabilidade e a eficácia de um *pipeline* de DL, baseado em TL e ajuste fino, para a classificação de doenças e estresses nutricionais em folhas de soja. A metodologia rigorosa, desde a curadoria dos dados até a avaliação abrangente, resultou em um modelo com desempenho de alta *performance*, validado por métricas que atestam sua alta precisão, robustez estatística e poder de discriminação. Conclui-se que a abordagem proposta não apenas atinge os objetivos acadêmicos, mas também estabelece uma base tecnológica sólida para o desenvolvimento de ferramentas de apoio à decisão na agricultura de precisão. O estudo reforça, assim, o potencial da IA como um vetor de inovação para um monitoramento agrícola mais eficiente, sustentável e orientado por dados.

REFERÊNCIAS

- ARAÚJO, M. B. S. d. Uso de métodos convencionais e inteligência artificial para mapeamento de *spermacoce verticillata* em lavoura de soja. UFMA, 2023.
- BARBEDO, J. G. A. Plant disease identification from individual lesions and spots using deep learning. **Biosystems engineering**, Elsevier, v. 180, p. 96–107, 2019.
- BERNARDOCKI, P.; MURAKAMI, R. G.; COSTA, B. A. Conectividade na agricultura: Barreiras e benefícios. **Revista de Inovação e Tecnologia-RIT**, v. 13, n. 1, p. 55, 2023.
- BERTHIER, E. *et al.* The pléiades glacier observatory: high-resolution digital elevation models and ortho-imagery to monitor glacier change. **The Cryosphere**, Copernicus Publications Göttingen, Germany, v. 18, n. 12, p. 5551–5571, 2024.
- CASTRO, J. Q. Imagens de satélites e uav no monitoramento de uma lavoura de soja. UFMA, 2023.
- COHEN, J. A coefficient of agreement for nominal scales. **Educational and psychological measurement**, Sage Publications Sage CA: Thousand Oaks, CA, v. 20, n. 1, p. 37–46, 1960.
- COSTA, R. P. d. *et al.* Identificação de doenças em folhas de soja utilizando redes neurais convolucionais. Blumenau, SC., 2023.
- DAS, P. K. *et al.* Deep learning for plant disease detection and classification: A systematic analysis and review. **Current Applied Science And Technology**, p. e0259016–e0259016, 2024.
- FAWCETT, T. An introduction to roc analysis tom. **Irbm**, v. 35, n. 6, p. 299–309, 2005.
- FERENTINOS, K. P. Deep learning models for plant disease detection and diagnosis. **Computers and electronics in agriculture**, Elsevier, v. 145, p. 311–318, 2018.
- FERREIRA, J. A. *et al.* O uso da inteligência artificial na agricultura. **Revista Multidisciplinar do Nordeste Mineiro**, v. 9, n. 1, 2024.
- FERREIRA, M. V. S. Integração de tecnologias na agricultura de precisão: otimização sustentabilidade na produção agrícola. 2025.
- GUEBSI, R.; MAMI, S.; CHOKMANI, K. Drones in precision agriculture: A comprehensive review of applications, technologies, and challenges. **Drones**, MDPI, v. 8, n. 11, p. 686, 2024.
- GUO, C. *et al.* On calibration of modern neural networks. *In*: PMLR. **International conference on machine learning**. [S.l.: s.n.], 2017. p. 1321–1330.
- HE, K. *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.

ITO, M. F. Principais doenças da cultura da soja e manejo integrado. **Nucleus**, Fundação Educacional Ituverava, v. 10, n. 3, p. 83–101, 2013.

JACOBSEN, K. Mapping with skysat images. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, Copernicus GmbH, v. 43, p. 99–106, 2022.

JORGE, L. A. de C.; INAMASU, R. Y. Uso de veículos aéreos não tripulados (vant) em agricultura de precisão. **Ferramentas para agricultura de precisão**, v. 8, p. 109, 2013.

JUNIOR, L. G. d. S. **Diagnóstico precoce de ataque de pragas em plantas usando imagens de fluorescência**. 2024. Tese (Doutorado) — Universidade de São Paulo, 2024.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. **Advances in neural information processing systems**, v. 25, 2012.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **nature**, Nature Publishing Group UK London, v. 521, n. 7553, p. 436–444, 2015.

LUKAS, V. *et al.* The combination of uav survey and landsat imagery for monitoring of crop vigor in precision agriculture. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, Copernicus GmbH, v. 41, p. 953–957, 2016.

MATESE, A. *et al.* Are unmanned aerial vehicle-based hyperspectral imaging and machine learning advancing crop science? **Trends in Plant Science**, Elsevier, v. 29, n. 2, p. 196–209, 2024.

MCBRATNEY, A. *et al.* Future directions of precision agriculture. **Precision agriculture**, Springer, v. 6, n. 1, p. 7–23, 2005.

MOHANTY, S. P.; HUGHES, D. P.; SALATHÉ, M. Using deep learning for image-based plant disease detection. **Frontiers in plant science**, frontiers, v. 7, p. 215232, 2016.

MULLA, D. J. Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. **Biosystems engineering**, Elsevier, v. 114, n. 4, p. 358–371, 2013.

NUNES, E. C. Employing drones in agriculture: an exploration of various drone types and key advantages. **arXiv preprint arXiv:2307.04037**, 2023.

PAINO, E. D.; BEARARE, S. C. Integração de robôs autônomos e big data na agricultura de precisão: arquiteturas, automação e desafios de segurança para um ecossistema conectado: Integrating autonomous robots and big data in precision agriculture: architectures, automation and security challenges for a connected ecosystem. **RCMOS-Revista Científica Multidisciplinar O Saber**, v. 1, n. 1, 2025.

PAN, S. J.; YANG, Q. A survey on transfer learning. **IEEE Transactions on knowledge and data engineering**, IEEE, v. 22, n. 10, p. 1345–1359, 2009.

PESSI, D. D. *et al.* Aeronaves remotamente pilotadas e suas aplicações no manejo agrícola e ambiental. **Cadernos de Ciência & Tecnologia**, v. 37, n. 2, p. e26605–e26605, 2020.

- PINHEIRO, J. N.; FREITAS, B. M. Efeitos letais dos pesticidas agrícolas sobre polinizadores e perspectivas de manejo para os agroecossistemas brasileiros. **CEP**, v. 60021, p. 970, 2010.
- PROVOST, F.; FAWCETT, T. **Data Science for Business: What you need to know about data mining and data-analytic thinking**. [S.l.: s.n.]: "O'Reilly Media, Inc.", 2013.
- RAJ, M. *et al.* Leveraging precision agriculture techniques using uavs and emerging disruptive technologies. **Energy Nexus**, Elsevier, v. 14, p. 100300, 2024.
- RIJSBERGEN, C. V. Information retrieval 2nd edition butterworths. **London available on internet**, 1979.
- SANTI, A. L. *et al.* Agricultura de precisão no manejo de pragas na cultura da soja no sul do brasil. **BERNARDI, ACC, NAIME, JM, RESENDE, AV, BASSOI, LH, INAMASU, RY Agricultura de precisão: resultados de um novo olhar. Brasília, DF. Embrapa**, 2014.
- SARAIVA, A. M. *et al.* A inteligência artificial na pesquisa agrícola. **Revista USP**, n. 141, p. 91–106, 2024.
- SHORTEN, C.; KHOSHGOFTAAR, T. M. A survey on image data augmentation for deep learning. **Journal of big data**, Springer, v. 6, n. 1, p. 1–48, 2019.
- SILVA, J. C. Classificação de doenças agrícolas por imagem. 280, 2024.
- SOUZA, L. N. Repositório GitHub, **Identificação de Doenças e Estresses Nutricionais em Soja Utilizando Visão Computacional e Aprendizado por Transferência**. São Carlos, SP: [S.l.: s.n.], 2025. <https://github.com/LobatoSouza/tcc-soja-visao-computacional>. Repositório público do notebook final do Trabalho de Conclusão de Curso (MBA em Inteligência Artificial e Big Data — ICMC/USP).
Download direto do notebook: https://github.com/LobatoSouza/tcc-soja-visao-computacional/raw/main/TCC_Lobato_Visao_Computacional.ipynb.
- TAURION, C. **Big data**. [S.l.: s.n.]: Brasport, 2013.
- WESSNER, R. N.; FROZZA, R.; MOLZ, R. F. Métodos para identificação de plantas daninhas em lavouras de milho com uso de inteligência artificial e processamento de imagens: revisão de literatura. **Revista Produção Online**, v. 24, n. 2, p. 5249–5249, 2024.