

Raglicia Sandi Ribeiro de Sousa
Orientador: Júlio Vítor Monteiro Marques
Co-orientador: Frank César Lopes Verás

Identificação de doenças no cajueiro usando visão computacional e processamento de imagens

Picos - PI
13 de junho de 2025

Raglicia Sandi Ribeiro de Sousa
Orientador: Júlio Vítor Monteiro Marques
Co-orientador: Frank César Lopes Verás

Identificação de doenças no cajueiro usando visão computacional e processamento de imagens

Modelo de Trabalho de Conclusão de Curso em Bacharelado em Sistemas de Informação na Universidade Federal do Piauí. Este modelo está em conformidade com as normas ABNT.

Universidade Federal do Piauí
Campus Senador Heuvídio Nunes de Barros
Bacharelado em Sistemas de Informação

Picos - PI
13 de junho de 2025

FICHA CATALOGRÁFICA
Serviço de Processamento Técnico da Universidade Federal do Piauí
Biblioteca José Albano de Macêdo

S725i Sousa, Raglicia Sandi Ribeiro de.
Identificação de doenças no cajueiro usando visão computacional e processamento de imagens / Raglicia Sandi Ribeiro de Sousa – 2025.
36 f.

1 Arquivo em PDF.
Indexado no catálogo *online* da biblioteca José Albano de Macêdo-CSHNB Aberto a pesquisadores, com restrições da Biblioteca.

Trabalho de Conclusão de Curso (Graduação) – Universidade Federal do Piauí, Curso de Bacharelado em Sistemas de Informação, Picos, 2025.
“Orientador: Júlio Vítor Monteiro Marques”.
“Co-orientador: Frank César Lopes Verás”.

1. Sistemas informacionais. 2. Visão computacional. 3. Recuperação da informação – monitoramento. I. Sousa, Raglicia Sandi Ribeiro de. II. Marques, Júlio Vítor Monteiro. III. Verás, Frank César Lopes. IV. Título.

CDD 005.7

Elaborada por Maria Letícia Cristina Alcântara Gomes
Bibliotecária CRB n° 03/1835

IDENTIFICAÇÃO DE DOENÇAS NO CAJUEIRO USANDO VISÃO COMPUTACIONAL E PROCESSAMENTO DE IMAGENS

RAGLÍCIA SANDI RIBEIRO DE SOUSA

Monografia aprovada como exigência parcial para obtenção do grau de Bacharel em Sistemas
de Informação.

Data de Aprovação

Picos – PI, 26 de JUNHO de 2025

Documento assinado digitalmente
 **JULIO VITOR MONTEIRO MARQUES**
Data: 05/07/2025 15:46:11-0300
Verifique em <https://validar.iti.gov.br>

Prof. Júlio Vitor Monteiro Marques

Documento assinado digitalmente
 **ISMAEL DE HOLANDA LEAL**
Data: 08/07/2025 10:19:04-0300
Verifique em <https://validar.iti.gov.br>

Prof. Ismael de Holanda Leal

Documento assinado digitalmente
 **ANTHONY IRLAN MARQUES LUZ**
Data: 06/07/2025 10:29:13-0300
Verifique em <https://validar.iti.gov.br>

Prof. Anthony Irlan Marques Luz

Agradecimentos

Agradeço, primeiramente, a Deus, que me deu forças e sabedoria para vencer os desafios dessa caminhada. Sem Ele, não teria sido possível chegar até aqui.

Dedico todo e qualquer sucesso aos meus pais, Clemilda Ribeiro de Oliveira e Manoel de Sousa Filho, que, mesmo sob muito sol, me deram sombra e água fresca para chegar até aqui. Minha profunda gratidão a vocês. Se segui firme nesta trajetória, foi graças ao amor, apoio e valores que sempre me transmitiram. O carinho e os conselhos de vocês foram essenciais para que eu nunca desistisse, mesmo nas maiores dificuldades. Tudo o que conquistei reflete o exemplo e a força que recebi de vocês.

Às minhas irmãs, Maria Raiane Ribeiro de Sousa e Maria Raisse Ribeiro de Sousa, agradeço de coração. O apoio, o carinho e a presença de vocês me deram força para seguir em frente, mesmo nos momentos mais difíceis.

Agradeço a todos os professores que, com dedicação e excelência, contribuíram para a minha formação acadêmica e pessoal, transmitindo não apenas conhecimento, mas também inspiração e valores. De forma muito especial, expressei minha sincera gratidão ao meu orientador e professor Júlio Vítor Monteiro Marques, por todo o apoio, paciência, orientações e valiosos ensinamentos ao longo de toda a pesquisa. Sua persistência e dedicação foram fundamentais para a realização e o aperfeiçoamento deste trabalho. Agradeço também ao meu coorientador Frank César Veras Lopes, pelo suporte e contribuições relevantes durante o desenvolvimento deste trabalho.

Meu sincero agradecimento ao meu namorado, Vinicius de Sousa Carvalho, que foi meu alicerce durante toda essa jornada. Em meio aos desafios e momentos árdios do curso, seu apoio constante, amor e companheirismo transformaram cada obstáculo em motivação, tornando o caminho mais leve e cheio de esperança. Este trabalho carrega um pouco dele, de todo o carinho que recebi, sendo fruto da força que ele me ajudou a encontrar, mesmo quando eu não sabia que tinha.

Agradeço imensamente às minhas amigas, Janiele Sousa, Larisse Melo, Naiana Silva e Raislara Araujo, que estiveram ao meu lado durante essa trajetória. O incentivo e as palavras de conforto de vocês foram fundamentais, especialmente nos momentos difíceis. A presença de cada uma tornou essa caminhada mais leve e cheia de significado.

Gostaria de fazer um agradecimento especial às minhas amigas Raila Verina e Viviane Barbosa, que sempre acreditaram em mim e me incentivaram, mesmo quando eu duvidava. O apoio, a motivação e a coragem de vocês foram fundamentais para me manter firme nos momentos difíceis.

Por fim, agradeço a mim mesma por não ter desistido nos momentos difíceis, por ter persistido mesmo diante do cansaço e das incertezas. Agradeço pela coragem, dedicação e esforço para superar obstáculos e crescer com os desafios. Esta conquista é minha, mas

também de todos que caminharam comigo, me apoiaram e acreditaram em mim.

A vida não é sobre esperar a tempestade passar, é sobre aprender a dançar na chuva.
Judith Beck

Resumo

O cajueiro tem um papel crucial na economia e subsistência de diversas comunidades no Brasil. Tanto a castanha quanto o pseudofruto, o caju, são essenciais para o comércio local, contribuindo significativamente para a geração de empregos. Reconhecendo essa importância, a implementação de técnicas de visão computacional e processamento de imagens surge como uma abordagem promissora. Essas tecnologias possibilitam um monitoramento eficaz da saúde das plantações, permitindo intervenções preventivas que reduzem a dependência de trabalho humano e aumentam a eficiência dos métodos tradicionais.

O cultivo de cajueiros é severamente impactado pela ocorrência de doenças bacterianas e fúngicas, que representam desafios significativos para a detecção e gestão eficaz. Entre as principais doenças fúngicas encontram-se a antracnose, a gomose causada pelo fungo *Phytophthora* e o oídio. Adicionalmente, doenças bacterianas como a mancha bacteriana também comprometem seriamente a produção. O diagnóstico dessas patologias é frequentemente dificultado pelo custo financeiro das técnicas manuais convencionais. Os danos causados por estas doenças às folhas, frutos e galhos podem resultar em perdas significativas de produção e prejuízos econômicos, afetando diretamente a qualidade e a quantidade da colheita. Neste trabalho, foi desenvolvido um sistema de detecção automatizada de doenças em folhas de cajueiro por meio de visão computacional e redes neurais convolucionais. A arquitetura VGG16, pré-treinada no *ImageNet*, foi utilizada para extração de características, e combinada com técnicas de pré-processamento e aumento de dados. Para validação, foi construída uma base própria contendo 100 imagens, divididas entre folhas saudáveis e doentes. O modelo foi treinado por 30 épocas e testado com imagens inéditas, obtendo acurácia de 90%. Os resultados demonstraram desempenho satisfatório, com precisão de 86% e *recall* de 97% para a classe “doente”, além de 97% e 84%, respectivamente, para a classe “saudável”. Tais métricas evidenciam a robustez da solução proposta, que se mostra eficaz para uso em campo, contribuindo para a identificação precoce de doenças como antracnose, oídio, mancha bacteriana e gomose.

Palavras-chaves: Aprendizado profundo, Doenças do cajueiro, Processamento de imagem, Visão computacional, VGG.

Abstract

The cashew tree plays a crucial role in the economy and livelihood of various communities in Brazil. Both the cashew nut and the pseudofruit, the cashew apple, are essential to the local trade, significantly contributing to job creation. Recognizing this importance, the implementation of computer vision and image processing techniques emerges as a promising approach. These technologies enable effective monitoring of crop health, allowing for preventive interventions that reduce reliance on manual labor and increase the efficiency of traditional methods.

Cashew cultivation is severely affected by the occurrence of bacterial and fungal diseases, which pose significant challenges to effective detection and management. Among the main fungal diseases are anthracnose, gummosis caused by the *Phytophthora* fungus, and powdery mildew. Additionally, bacterial diseases such as bacterial spot also seriously compromise production. The diagnosis of these pathologies is often hindered by the financial cost of conventional manual techniques. The damage caused by these diseases to leaves, fruits, and branches can lead to significant production losses and economic damage, directly affecting both the quality and quantity of the harvest.

In this work, an automated disease detection system for cashew tree leaves was developed using computer vision and convolutional neural networks. The VGG16 architecture, pre-trained on ImageNet, was used for feature extraction and combined with preprocessing and data augmentation techniques. For validation, a proprietary dataset containing 100 images was built, divided between healthy and diseased leaves. The model was trained for 30 epochs and tested with unseen images, achieving an accuracy of 90%. The results demonstrated satisfactory performance, with a precision of 86% and recall of 97% for the “diseased” class, as well as 97% and 84%, respectively, for the “healthy” class. These metrics highlight the robustness of the proposed solution, which proves effective for field application, contributing to the early identification of diseases such as anthracnose, powdery mildew, bacterial spot, and gummosis.

Lista de ilustrações

Figura 1 – Sintomas de antracnose: (A) Manchas pretas nas folhas, (B) Aborto de flores, (C) Mancha preta na noz. fonte: (WONNI et al., 2017)	16
Figura 2 – Danos por gomose: Em (A) tronco, em (B) galhos. fonte: (WONNI et al., 2017)	17
Figura 3 – Sintomas de doenças bacterianas: (A) Mancha preta na folha (B) cancro do caule, (C) Mancha preta na porca. fonte (WONNI et al., 2017)	17
Figura 4 – Oídio (B). fonte:(WONNI et al., 2017)	18
Figura 5 – Etapas fundamentais da visão computacional, incluindo: coleta de imagem, pré-processamento, extração de características, detecção e segmentação.	18
Figura 6 – Exemplo de uma rede neural convolucional e suas diferentes camadas. Fonte: (VARGAS; PAES; VASCONCELOS, 2016)	20
Figura 7 – Metodologia proposta.	25
Figura 8 – Aplicação de aumento de dados.	26
Figura 9 – Arquitetura da rede VGG-Very-Deep-16. Fonte: (DING et al., 2021)	27
Figura 10 –Imagem saudável classificado como saudável	30
Figura 11 –Imagem doente classificado como doente	30
Figura 12 –Imagem Doente classificado como saudável	31
Figura 13 –Imagem saudável classificado como doente	31

Lista de tabelas

Tabela 1 – Trabalhos relacionados	24
Tabela 2 – Relatório de classificação do modelo	29
Tabela 3 – Desempenho dos Modelos na Detecção de Doenças em Plantas	32

Lista de abreviaturas e siglas

VGG	Visual Geometry Group
AI	Artificial Intelligence
CNN	Convolutional Neural Network
AM	Aprendizado de Máquina (Machine Learning)
DWT	Discrete Wavelet Transform
GLCM	Gray Level Co-occurrence Matrix
INT8	Inteiro com 8 bits
KNN	K-Nearest Neighbors (K-Vizinhos Mais Próximos)
ML	Machine Learning (Aprendizado de Máquina)
YOLOv5	You Only Look Once version 5 (modelo de detecção em tempo real)
SVM	Support Vector Machine (Máquina de Vetores de Suporte)
TMB	Tea Mosquito Bug
PCA	Principal Component Analysis (Análise de Componentes Principais)

Lista de símbolos

Γ	Letra grega Gama
Λ	Lambda
ζ	Letra grega minúscula zeta
\in	Pertence

Sumário

1	Introdução	14
1.1	Objetivos	15
1.1.1	Objetivos Específicos	15
1.2	Estrutura do Trabalho	15
2	Referencial Teórico	16
2.1	Doenças do cajueiro	16
2.2	Visão Computacional	17
2.3	Inteligência artificial	19
2.3.0.1	Aprendizado de maquina	19
2.3.0.2	Aprendizado profundo	20
3	Trabalhos Relacionados	22
4	Metodologia	25
4.1	Aquisição das Imagens	25
4.2	Pré-processamento das Imagens	26
4.3	Classificação	27
4.4	Avaliação	28
5	Resultados	29
5.0.1	Análise Quantitativa do Desempenho	29
5.0.2	Análise Qualitativa das Predições	29
6	Discussão	32
7	Conclusão	34
	Referências	35

1 Introdução

Segundo (AGUIAR et al., 2001), o cajueiro (*Anacardium occidentale*), originário do Brasil, é essencial para a economia e subsistência de diversas comunidades, especialmente nos estados do Piauí, Ceará e Rio Grande do Norte. Segundo dados do IBGE (Associação de Engenheiros Agrônomos de Sergipe (AEASE), 2023), esta planta é valorizada não apenas por suas propriedades nutricionais, mas também pelo papel significativo que desempenha na economia local. O comércio de seus frutos, o caju e a castanha, contribui para a criação de empregos em atividades como colheita, processamento e comercialização. Além disso, o aproveitamento integral dos recursos do cajueiro, incluindo bagaço, frequentemente considerado um resíduo, para ração animal, evidencia a eficiência e a sustentabilidade dessa cultura, promovendo o desenvolvimento econômico local de maneira sustentável.

No entanto, conforme destacado por (GAMA et al., 2015), diversas doenças, principalmente fúngicas e bacterianas, representam uma ameaça significativa à saúde e à produtividade dos cajueiros. A antracnose, causada pelo fungo *Colletotrichum gloeosporioides*, é uma das doenças fúngicas mais comuns e danosas, afetando folhas jovens, plantas adultas e castanhas, o que resulta na queda prematura das frutas e na diminuição do rendimento da colheita. Outras doenças fúngicas, como a gomose, provocada pelo fungo *Phytophthora*, atacam troncos e galhos, causando a queda de folhas e amarelecimento, prejudicando severamente a produção. Além disso, o oídio, outra doença fúngica comum, provoca manchas em folhas, pedúnculos e castanhas, tornando-as impróprias para a comercialização. No que diz respeito às doenças bacterianas, a mancha-bacteriana (*Xanthomonas*) também é uma preocupação, pois provoca danos significativos às folhas e frutos, comprometendo a qualidade das frutas o que resulta em menor produtividade impactando negativamente a comercialização.

Diante desses desafios, a visão computacional emerge como uma ferramenta essencial para a agricultura contemporânea. De acordo com (MAHENDRAN, 2023), existem estudos recentes que aplicam técnicas de aprendizado de máquina para a detecção de doenças em cajueiros, baseando-se em sintomas visíveis. Essas metodologias proporcionam maior precisão na identificação de patologias vegetais, o que permite aos agricultores diagnosticar e intervir em problemas fitossanitários de forma mais eficiente.

Frente a esse cenário, a detecção precoce de doenças é fundamental para a agricultura, particularmente devido ao impacto econômico e social significativo que patógenos emergentes podem ter. Conforme (MONTEIRO et al., 2015) destacam, as doenças infecciosas emergentes, seja por adaptação às condições locais ou pela importação inadvertida de agentes patogênicos, podem resultar em perdas substanciais na produção de caju. Estas perdas são frequentemente subestimadas, especialmente nos países em desenvolvimento.

Nesse sentido, medidas preventivas são essenciais para preservar a segurança alimentar e o sustento das comunidades agrícolas, enfatizando a importância da vigilância constante tanto no campo quanto na fase de viveiro, como apontado por (PARLINDO; TONDOK; WIYONO, 2022).

1.1 Objetivos

O objetivo deste trabalho é desenvolver uma ferramenta de auxílio para a identificação automatizada de doenças em cajueiros. Esta ferramenta busca simplificar e otimizar o processo de detecção de doenças, proporcionando uma redução significativa nos custos financeiros, operacionais, e humanos associados à gestão fitossanitária.

1.1.1 Objetivos Específicos

- Coletar um conjunto de imagens de cajueiros com folhas saudáveis e infectadas por doenças.
- Desenvolver um sistema de visão computacional capaz de identificar a presença de doenças nas folhas dos cajueiros com precisão, utilizando técnicas de processamento de imagens e aprendizado de máquina.
- Avaliar a eficácia dos modelos de aprendizado de máquina desenvolvidos por meio de métricas de avaliação.

1.2 Estrutura do Trabalho

Este trabalho está estruturado em 5 capítulos além da introdução, conforme descrito a seguir: O Capítulo 2 contempla os conceitos e as principais técnicas essenciais, contribuindo para uma melhor compreensão do trabalho, assim como as métricas utilizadas. O Capítulo 3 apresenta uma breve revisão da literatura, destacando os principais estudos relacionados ao tema. O Capítulo 4 descreve a metodologia empregada, incluindo as principais estratégias para cada fase do desenvolvimento. O Capítulo 5, por sua vez, discute os resultados obtidos e apresenta informações adicionais relevantes. Por fim, o Capítulo 6 e apresenta as considerações finais do trabalho, além de indicar possíveis direções para pesquisas futuras.

2 Referencial Teórico

Nesse capítulo, serão apresentados conceitos fundamentais para a compreensão do projeto, como visão computacional, inteligência artificial, processamento de imagem e doenças do cajueiro.

2.1 Doenças do cajueiro

O cajueiro (*Anacardium occidentale L.*), tem sido levado para diferentes agroecossistemas em razão do seu potencial de geração de emprego e renda em regiões onde é difícil encontrar alternativas economicamente mais rentáveis (PAIVA; CRISÓSTOMO; BARROS, 2003). A produção de cajueiro envolve diversas etapas que geram empregos, dentre elas estão o plantio, colheita e processamento dos frutos e castanhas. Sendo assim, o cajueiro oferece oportunidades de trabalho para agricultores, trabalhadores rurais, e comerciantes, contribuindo para a economia local. Entretanto, segundo (HAWERROTH et al., 2017), a ocorrência de doenças durante o período produtivo devido ao controle ineficiente, tem causado uma redução significativa da produção de castanhas e pedúnculos nos cajueirais nacionais. De acordo com (WONNI et al., 2017), as doenças mais comuns são:

- A antracnose, causada pelo fungo (*Colletotrichum gloeosporioides*), foi a doença mais disseminada e com elevada incidência em todas as áreas de produção. Os sintomas de antracnose foram observados nas folhas, inflorescências e castanha, doença essa ilustrada na Figura 1.

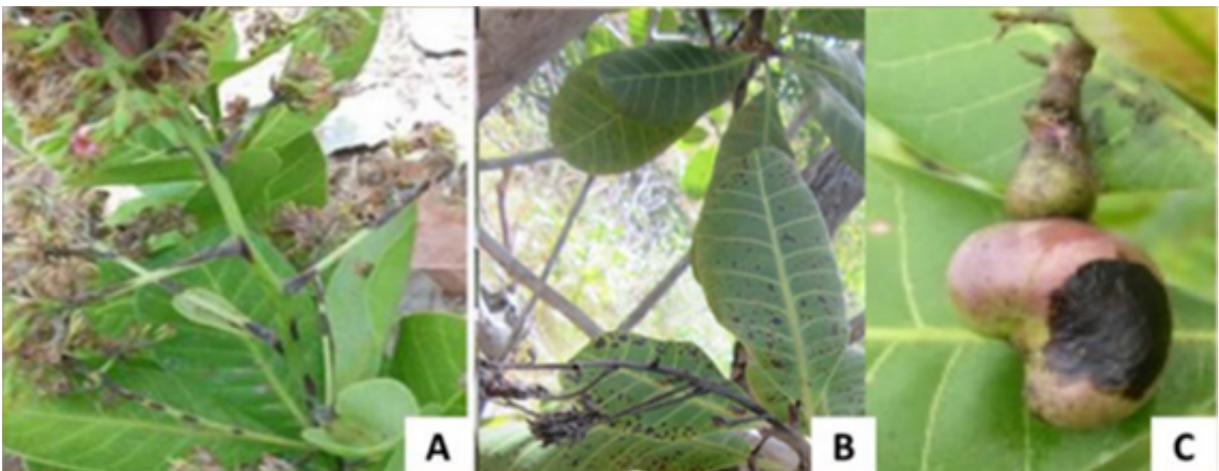


Figura 1 – Sintomas de antracnose: (A) Manchas pretas nas folhas, (B) Aborto de flores, (C) Mancha preta na noz. fonte: (WONNI et al., 2017)

- A gomose provocada pelo fungo do gênero *Phytophthora* foi caracterizada por ex-

sudação de goma no tronco e galhos e que é o sintoma mais visível após amarelecimento e queda das folhas. Na Figura 2, é possível observar o aspecto típico da gomose.



Figura 2 – Danos por gomose: Em (A) tronco, em (B) galhos. fonte: (WONNI et al., 2017)

- A mancha bacteriana foliar (*Mancha-de-Xanthomonas*), mais conhecida como Cancro Bacteriano, foram caracterizados por manchas de necrose angular, localizadas próximas às nervuras das folhas, cancro nos galhos e manchas oleosas tornando-se necróticas na noz. Uma ilustração dessa mancha bacteriana pode ser vista na Figura 3.

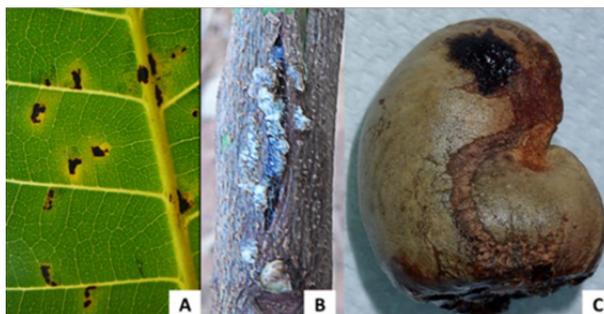


Figura 3 – Sintomas de doenças bacterianas: (A) Mancha preta na folha (B) cancro do caule, (C) Mancha preta na porca. fonte (WONNI et al., 2017)

- O oídio causado pelo fungo *Erysiphe quercicola*, é caracterizada por colônias de míldio esbranquiçadas ou esbranquiçadas observadas na superfície superior das folhas das plantas hospedeiras. A Figura 4 ilustra as características do oídio.

2.2 Visão Computacional

A visão computacional pode ser definida como uma série de métodos e técnicas empregados para interpretar imagens, visando a simulação computacional da visão humana (ALMEIDA; CORSO; JR, 2007). Segundo (MILANO; HONORATO, 2010), ela capacita o computador a extrair uma vasta gama de informações precisas de imagens e vídeos, possibilitando a realização de tarefas inteligentes que aproximam-se da capacidade humana de interpretação. A Figura 5 ilustra as funcionalidades comuns na maioria dos sistemas de visão computacional, conforme indicado por (REHEM; TRINDADE, 2009):



Figura 4 – Oídio (B). fonte:(WONNI et al., 2017)

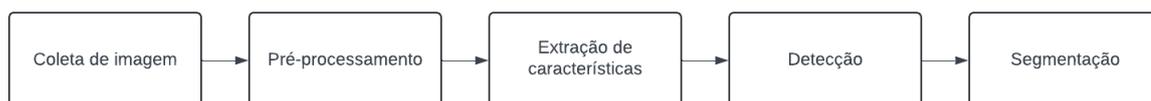


Figura 5 – Etapas fundamentais da visão computacional, incluindo: coleta de imagem, pré-processamento, extração de características, detecção e segmentação.

- **Aquisição de Imagem:** Esta é a etapa inicial, na qual se realiza a captação de uma imagem ou conjunto de imagens através de sensores de câmeras. Os pixels de cada imagem captada representam coordenadas de luz e propriedades físicas.(MILANO; HONORATO, 2014)

- **Pré-processamento:** Antes de extrair informações, as imagens passam por técnicas de pré-processamento que facilitam a identificação de objetos. As técnicas de pré-processamento podem incluir a aplicação de filtros para remover ruídos, realçar detalhes ou suavizar as imagens, melhorando assim a qualidade visual para análise e interpretação humanas ou processamento computacional posterior (GONZALEZ; WOODS, 2000).

- **Extração de Características:** Consiste na extração de características matemáticas de uma imagem, identificando elementos como textura, bordas e formas, essenciais para o reconhecimento de padrões.(MILANO; HONORATO, 2014)

- **Detecção e Segmentação:** Este processo envolve destacar e segmentar regiões relevantes da imagem para facilitar análises subsequentes.(MILANO; HONORATO, 2014)

As tecnologias de visão computacional e processamento de imagens têm sido amplamente utilizadas em diversas aplicações práticas. Essas aplicações incluem a astronomia, medicina, análise de impressões digitais, robótica de manipuladores, robótica móvel e sistemas produtivos, demonstrando a importância e a versatilidade dessas tecnologias como destacado por (RUDEK; COELHO; JR, 2001).

2.3 Inteligência artificial

A inteligência artificial (IA) é um campo da computação dedicado ao desenvolvimento de sistemas e tecnologias capazes de executar tarefas que tradicionalmente requerem inteligência humana, como reconhecimento de padrões em imagens, tomada de decisões complexas e resolução de problemas. A IA envolve o uso de rotinas lógicas que, aplicadas na ciência da computação, permitem que os computadores operem com autonomia, dispensando a supervisão humana para interpretar dados analógicos e digitais (FILHO, 2018).

Entre as subáreas de maior impacto da Inteligência Artificial, destaca-se o *Machine Learning* (Aprendizado de Máquina), que equipa os computadores com a capacidade de aprender e fazer inferências a partir de dados históricos. O *Deep Learning* (Aprendizado Profundo), uma extensão do *Machine Learning*, utiliza redes neurais profundas para aprender representações de dados em níveis de complexidade crescentes (GONÇALVES, 2020).

2.3.0.1 Aprendizado de máquina

Aprendizado de Máquina (AM), ou *Machine Learning* em inglês, é uma área dentro do campo da Inteligência Artificial. Essa área concentra-se no desenvolvimento de sistemas capazes de adquirir conhecimento autonomamente, ou seja, programas que aprendem a partir de experiências passadas e, com base nisso, tomam decisões de maneira autônoma (MONARD; BARANAUSKAS, 2003). Devido à sua capacidade de lidar com grandes volumes de dados e resolver problemas complexos onde a programação manual de algoritmos seria custosa ou impraticável, o AM destaca-se como uma ferramenta de grande valor (GOODFELLOW; BENGIO; COURVILLE, 2016).

Conforme (LIBRALÃO et al., 2003), o Aprendizado de Máquina pode ser classificado em três paradigmas principais:

- Supervisionado: onde o modelo é treinado com a ajuda de supervisores para alcançar a melhor performance desejada.
- Não-supervisionado: permite que o algoritmo aprenda a representar ou agrupar as entradas baseando-se em medidas de similaridade sem qualquer supervisão externa.
- Por reforço: o aprendizado ocorre através de recompensas com base no desempenho do algoritmo.

Um exemplo prático de aplicação do Aprendizado de Máquina é na área de visão computacional para a agricultura, onde, segundo (TEIXEIRA; FERREIRA, 2015), técnicas de AM têm sido aplicadas com sucesso na classificação e estimativa da produção de frutas, como ameixas e cajus. Essas aplicações mostram resultados promissores na melhoria da eficiência e precisão na agricultura, demonstrando a versatilidade e o potencial transformador do Aprendizado de Máquina.

2.3.0.2 Aprendizado profundo

O Aprendizado Profundo, ou *Deep Learning*, é uma subárea do Aprendizado de Máquina que utiliza redes neurais profundas para aprender representações de dados em múltiplos níveis de abstração (ZHANG; WANG; LIU, 2018). Essas redes são compostas por várias camadas de processamento não linear que transformam os atributos de entrada em saídas complexas, permitindo que o sistema desenvolva um entendimento sofisticado do conjunto de dados com o qual trabalha (MARQUES, 2016).

Uma arquitetura comum em *Deep Learning* é a Rede Neural Convolucional (CNN), que se destaca pela sua eficácia no processamento de dados visuais. Inspirada nos mecanismos biológicos de visão, a CNN consiste em várias camadas que transformam a imagem de entrada em saídas que podem ser usadas para classificação ou outras tarefas (VARGAS; PAES; VASCONCELOS, 2016). A figura 6 mostra um exemplo de uma arquitetura de CNN.

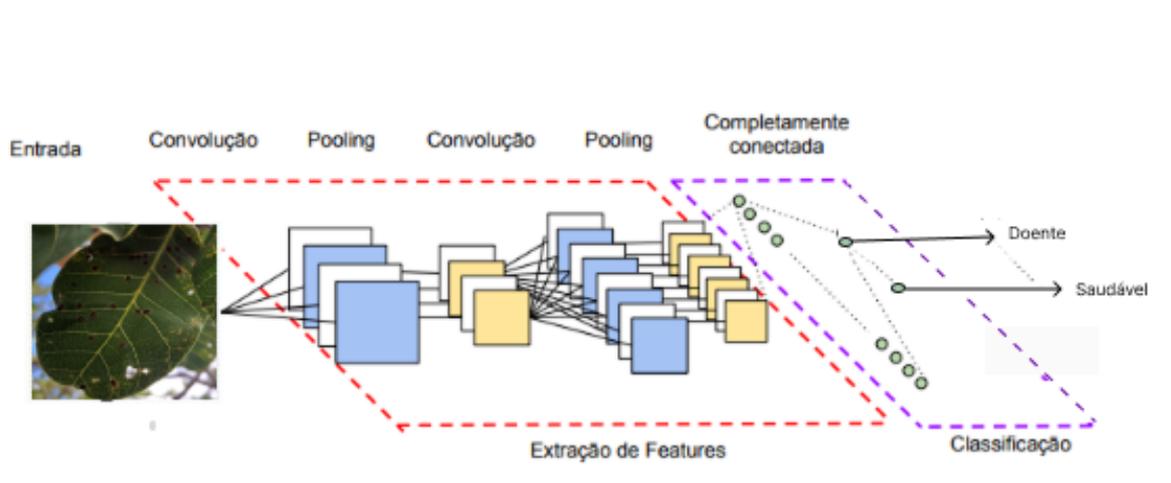


Figura 6 – Exemplo de uma rede neural convolucional e suas diferentes camadas. Fonte: (VARGAS; PAES; VASCONCELOS, 2016)

De acordo com (VARGAS; PAES; VASCONCELOS, 2016), as camadas funcionam da seguinte forma:

- Camada de Convolução: Aplica filtros que capturam características locais da imagem, como bordas e texturas. Cada filtro produz um mapa de características que serve como entrada para a próxima camada.
- Pooling: Reduz a dimensionalidade dos mapas de características, aumentando a eficiência computacional e a invariância a pequenas variações na posição das características dentro da imagem.
- Camada Totalmente Conectada: Combina todas as características aprendidas pelas camadas anteriores para realizar a classificação final ou tomar outras decisões baseadas nos dados.

Redes como as CNNs têm sido aplicadas com sucesso em uma variedade de campos, incluindo reconhecimento de imagens, análise de vídeo, condução autônoma e diagnóstico médico, demonstrando a versatilidade e eficácia do Aprendizado Profundo.

3 Trabalhos Relacionados

Neste Capítulo apresenta os trabalhos relacionados com este estudo sobre a identificação de doenças em cajueiros usando visão computacional. A Tabela 1 apresenta os trabalhos relacionados de acordo com 3 critérios: Técnicas de visão computacional e processamento de imagem para estudar uma planta específica e as doenças foco de cada pesquisa. A revisão foi realizada em bases acadêmicas reconhecidas, com critérios de inclusão definidos, permitindo categorizar temas, técnicas e resultados. A análise também identificou lacunas e oportunidades para futuras pesquisas, contribuindo para o avanço científico na área.

Em Kazi et al. (2023), foi proposto um sistema automatizado de classificação para melhorar o processo de inspeção de romãs, visando a qualidade e detecção de doenças. A metodologia incluiu o uso de algoritmos de aprendizado de máquina, como SVM (*Support Vector Machine*) e CNN, para classificar as frutas com base em características como cor, tamanho e forma. Técnicas de pré-processamento de imagem foram aplicadas, incluindo filtragem e segmentação, para aprimorar a qualidade das imagens capturadas. Os resultados mostraram que o sistema foi eficaz, alcançando uma precisão de aproximadamente 85,86% na detecção de doenças, o que pode ajudar os agricultores a melhorar a gestão de suas colheitas. No entanto, o trabalho enfrenta algumas limitações, como um banco de dados limitado, desafios com imagens de alta resolução, presença de ruídos nas imagens e a necessidade de melhorias na precisão do modelo CNN.

No artigo dos autores Abbas et al. (2023), o estudo propôs usar drones e sensoriamento remoto para identificar doenças em plantas, superando a lentidão e ineficácia dos métodos tradicionais nas fases iniciais da infecção. A metodologia utilizou drones com câmeras digitais, multiespectrais e hiperespectrais para captar imagens das plantações. Algoritmos de aprendizado de máquina e *deep learning* foram utilizados para identificar doenças em estágios iniciais, complementados por sensores térmicos e fluorescentes que capturam variações indicando estresse nas plantas. Os resultados indicam que drones combinados com algoritmos permitem identificar doenças de forma rápida e precisa, alcançando até 94,41% de acurácia em videiras, 85% de precisão em folhas, 86,3% de F1-score e 95,7% de sensibilidade em modelos de deep learning, que superaram métodos tradicionais. A solução é eficiente em custo e prática, mas enfrenta limitações como duração curta de voo, capacidade restrita de carga e resolução de imagens comprometida em altas altitudes.

Em Harakannanavar et al. (2022), o estudo propõe a automatização da detecção de doenças, superando as limitações da detecção manual. A metodologia incluiu o uso de imagens de folhas de tomate, redimensionadas e processadas com equalização de histograma, seguidas pela segmentação com K-means (BISHOP; NASRABADI, 2006), e a extração de características usando 3DWT (*3-Dimensional Wavelet Transform*), PCA (*Principal*

Component Analysis) e GLCM(*Gray Level Co-occurrence Matrix*). Foram usados três classificadores, o SVM(*Support Vector Machine*), CNN(*Convolutional Neural Network*) e KNN(*1ised*), com a CNN alcançando precisão de 99,6%. A abordagem demonstrou ser eficaz, fornecendo uma solução prática para os agricultores. porém, ainda existem algumas limitações como conjunto de dados limitado e ruído.

No artigo [Rajagopal e MS \(2023\)](#), propõe o uso de drones com câmeras e algoritmos de inteligência artificial (IA) para melhorar a precisão na detecção de doenças no cajueiro. A metodologia envolveu o uso de um drone equipado com um modelo de rede neural convolucional (CNN), baseado na arquitetura MobileNetV2([SANDLER et al., 2018](#)), otimizado para detecção em tempo real. Os resultados mostraram uma precisão de 99,2% na identificação de antracnose e 99% para folhas saudáveis. No entanto, o estudo mostra algumas limitações como o custo elevado para pequenos agricultores.

No artigo [Ouhami et al. \(2021\)](#), o estudo propõe o uso de visão computacional, inteligência artificial e dados de diversas fontes, como sensores IoT e imagens de drones, para aprimorar a identificação de doenças. A metodologia inclui uma revisão de técnicas de aprendizado de máquina, como SVM e redes neurais convolucionais, processando dados de diferentes fontes. Os resultados mostram alta precisão na detecção, com acurácias entre 80% e 97,85%, Modelos como ResNet atingiram 97,85% e combinações de sensores indicam grande potencial para monitoramento eficiente, embora exista a limitação de propriedade técnica como (resolução, brilho e etc..).

O trabalho [Vidhya e Priya \(2024\)](#), propõe uma abordagem para a detecção automatizada da gravidade da infestação do percevejo do chá (TMB) em plantas de cajueiro, utilizando o algoritmo YOLOv5([REDMON et al., 2016](#)). A pesquisa se baseia em um conjunto de dados composto por imagens de plantas saudáveis e infestadas, classificadas em níveis de severidade (leve, moderada, severa e extrema). O modelo foi treinado com Python, OpenCV e Torch, alcançando uma precisão de 92,6%, recall de 90,9% e F1-Score de 92,4%, demonstrando desempenho superior aos métodos convencionais. O artigo enfatiza a importância da detecção precoce de pragas para um manejo agrícola eficaz, contribuindo significativamente para a agricultura de precisão.

Por fim, diante das limitações observadas, como conjunto de dados limitado, presença de ruídos nas imagens e o elevado custo de implementação que inviabiliza o uso por pequenos agricultores além da necessidade de soluções eficientes para aplicação em campo, este trabalho propõe o desenvolvimento e a avaliação de um sistema baseado em visão computacional para a detecção automática de doenças em cajueiros, utilizando modelos de rede neural convolucionais, como VGG16. A avaliação dos modelos será realizada por meio de treino, validação e teste, utilizando métricas como acurácia, precisão, recall e F1-score. O objetivo deste trabalho é identificar uma abordagem que ofereça melhor desempenho e robustez frente aos desafios impostos pelos cenários reais de monitoramento fitossanitário em plantações de cajueiro.

Tabela 1 – Trabalhos relacionados

Trabalho	Técnica utilizada	Planta em estudo	Doenças
(KAZI et al., 2023)	SVM e CNN	Romã	Podridão de frutas e Cercospora
(ABBAS et al., 2023)	Aprendizado de máquina e deep learning	Trigo, milho, batata e tomate	Phytophthora infestans, Ralstonia solanacearum, Ervinia amylovora, Papillus mosaic virus e Tomato Mosaic Virus
(HARAKANNANAVAR et al., 2022)	K-means, DWT, PCA, GLCM, SVM, CNN	Tomates	ácaro-aranha-pintado, Target Spot, vírus mosaic, yellow curl
(RAJAGOPAL; MS, 2023)	CNN, MobileV2, INT8	Cajueiro	Antracnose
(OUHAMI et al., 2021)	Aprendizado de Máquina (incluindo SVM, KNN, Redes Neurais Convulsionalis - CNN, e aprendizado profundo)	varias plantas	Oídio, ferrugem, mofo cinzento, doença da batata-dourada, câncer bacteriano, antracnose, enrolamento foliar,
(VIDHYA; PRIYA, 2024)	YOLOv5	Cajueiro	Inseto do chá (TMB)
Este trabalho	Redes neurais convolucionais e pré - processamento de imagem	Cajueiro	Antracnose, Oídio, Mancha bacteriana foliar e Gomose

4 Metodologia

Esta seção apresenta a metodologia adotada para a realização deste trabalho, a qual está estruturada em quatro etapas principais: Aquisição das Imagens, Pré-processamento, Classificação e Avaliação. O fluxograma completo do processo é ilustrado na Figura 7. A seguir, cada uma dessas etapas é detalhada.

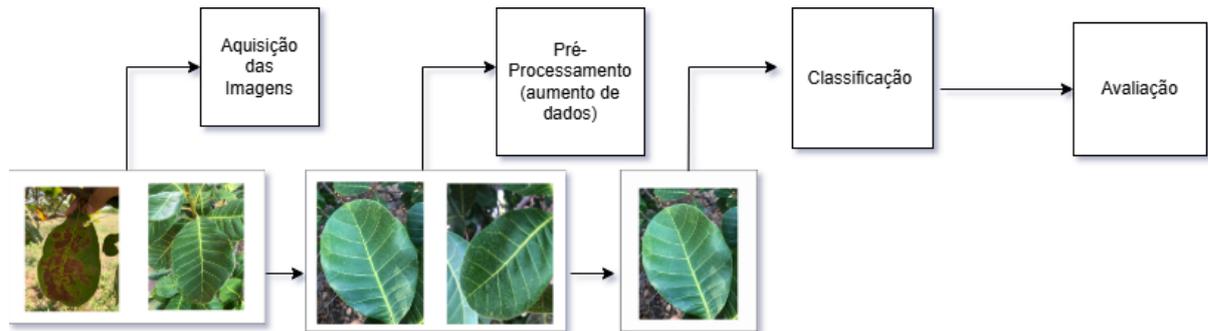


Figura 7 – Metodologia proposta. .

4.1 Aquisição das Imagens

A primeira etapa deste trabalho consistiu na construção de um conjunto de dados para o treinamento e validação dos modelos. Devido à ausência de bases de dados públicas adequadas para a classificação de patologias em folhas de cajueiro, foi necessária a criação de um repositório de imagens próprio. Essa abordagem, embora mais trabalhosa, garante que os dados representem as condições visuais específicas do problema a ser solucionado.

A coleta foi realizada em uma área rural no interior do estado do Piauí, Brasil, uma região com expressiva presença de plantações comerciais de cajueiro. As imagens foram capturadas utilizando um dispositivo móvel da marca Apple (iPhone 8 plus), em ambiente real e sob condições de iluminação natural variadas. O conjunto de dados resultante foi organizado em duas categorias fundamentais para o aprendizado supervisionado: folhas consideradas "saudáveis" e folhas que exibem características visuais de "doentes" (patologias).

A base de dados é composta por 100 imagens, com resolução média de 1200×1600 pixels. Para facilitar a manipulação computacional e o carregamento dos dados na fase de treinamento, as imagens foram separadas em diretórios distintos correspondentes a cada uma das classes, garantindo uma estrutura organizada e pronta para as etapas subsequentes do projeto. As imagens foram divididas em 70 para treinamento, 10 para validação e 20 para teste, seguindo a proporção adequada para o treinamento supervisionado. Todo o processamento e treinamento do modelo foram realizados no Google Colab, aproveitando sua infraestrutura para facilitar o desenvolvimento e a execução dos experimentos.

4.2 Pré-processamento das Imagens

A etapa de pré-processamento foi fundamental para padronizar as imagens e preparar o conjunto de dados para o treinamento do modelo. A principal transformação aplicada a todas as imagens foi a normalização de pixels, na qual os valores de cada pixel, originalmente no intervalo $[0, 255]$, foram reescalados para o intervalo $[0, 1]$. Este procedimento é essencial para garantir a estabilidade numérica durante o processo de otimização da rede neural e para acelerar a convergência do treinamento.

Para aumentar a diversidade do conjunto de dados e a capacidade de generalização do modelo, aplicou-se a técnica de aumento de dados (data augmentation) em tempo real durante o treinamento. Utilizando a classe `ImageDataGenerator`, foram aplicadas diversas transformações geométricas e de intensidade que simulam variações comumente encontradas em cenários reais de captura. Estas transformações incluíram a rotação aleatória, para simular diferentes ângulos de visualização da folha; translações horizontais e verticais, para representar pequenas variações no enquadramento da imagem; e o espelhamento horizontal, para criar novas perspectivas da mesma folha. Adicionalmente, foi utilizada a técnica de KNN (**K-Nearest Neighbors**) para lidar com os pixels que poderiam ser perdidos durante as transformações de rotação ou translação.

A aplicação conjunta dessas técnicas, ilustrada na Figura 8, enriqueceu artificialmente o conjunto de dados, expondo o modelo a uma gama mais ampla de exemplos e, consequentemente, mitigando o risco de sobreajuste (overfitting).

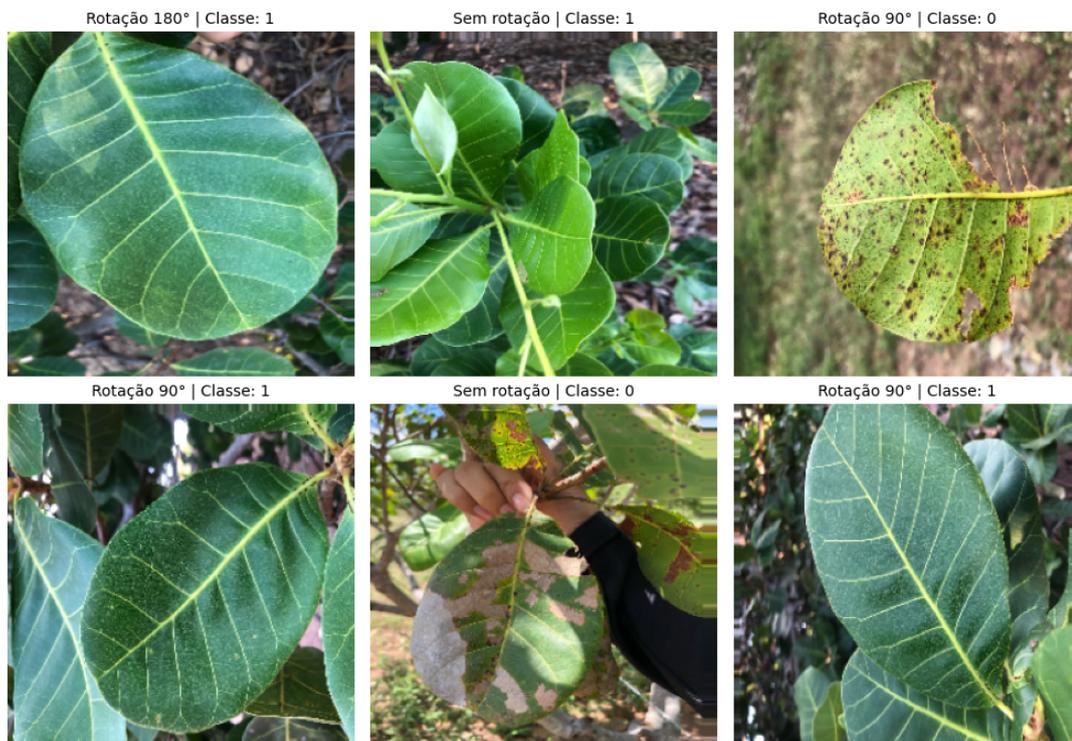


Figura 8 – Aplicação de aumento de dados.

4.3 Classificação

Para a tarefa de classificação, adotou-se uma abordagem baseada em aprendizado por transferência (*transfer learning*), utilizando a arquitetura VGG16 como extratora de características. A escolha deste modelo se justifica por sua arquitetura clássica, que serve como uma linha de base para o problema, além de ser amplamente reconhecida por sua alta capacidade de extrair características visuais. Sendo assim, o modelo, pré-treinado com o conjunto de dados ImageNet, teve sua base convolucional preservada, enquanto as camadas de topo (classificador original) foram removidas. Com o intuito de aproveitar o conhecimento previamente aprendido para o reconhecimento de padrões visuais genéricos, os pesos da base convolucional foram mantidos congelados, evitando que fossem alterados durante o treinamento.

Os mapas de características gerados pela base da VGG16 foram então processados por uma camada GlobalAveragePooling2D. Essa camada os converte em vetores de características unidimensionais, reduzindo a dimensionalidade dos dados e preparando-os para o classificador. A este extrator foi acoplada uma nova cabeça de classificação, projetada especificamente para a nossa tarefa. Esta consiste em uma sequência de camadas densas com 1024, 512 e 256 neurônios, utilizando a função de ativação ReLU para introduzir não-linearidades ao modelo. Na figura 9, temos um exemplo da estrutura.

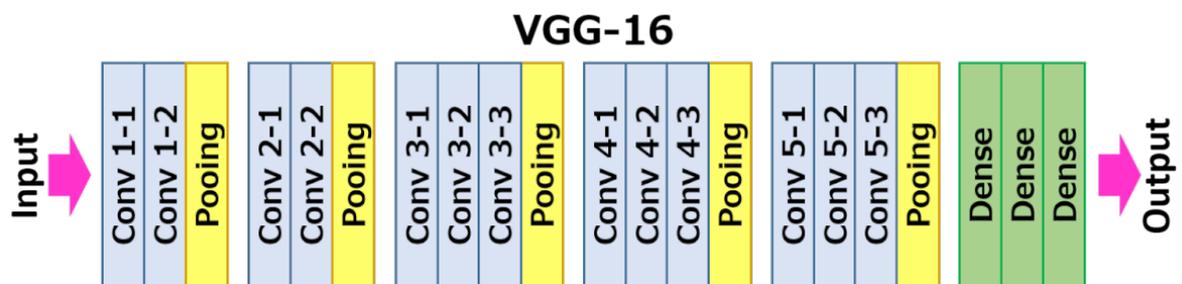


Figura 9 – Arquitetura da rede VGG-Very-Deep-16. Fonte: (DING et al., 2021)

Para mitigar o risco de sobreajuste (*overfitting*), foram incorporadas técnicas de regularização, como BatchNormalization após cada camada densa e Dropout em pontos estratégicos. A arquitetura é finalizada por uma camada de saída com um único neurônio e função de ativação sigmoide, configuração apropriada para problemas de classificação binária como o deste estudo. Essa abordagem, na qual apenas as novas camadas adicionadas são treinadas, representa um método de aprendizado por transferência para domínios com dados limitados.

4.4 Avaliação

A fase de validação foi conduzida para aferir a capacidade de generalização do modelo treinado na classificação de folhas de cajueiro entre as classes "saudável" e "doente". Para tal, o modelo foi submetido a um conjunto de teste, composto exclusivamente por imagens inéditas que não foram utilizadas nas etapas de treinamento. As imagens deste conjunto foram submetidas ao mesmo pipeline de pré-processamento descrito anteriormente, com a exceção da não aplicação de técnicas de aumento de dados, uma prática reservada apenas ao conjunto de treinamento para evitar viés na avaliação.

A performance do modelo foi avaliada quantitativamente por meio de um conjunto padrão de métricas: Acurácia (HART; STORK; WILEY, 2001), Precisão (FAWCETT, 2006), Revocação (Recall) (FAWCETT, 2006) e F1-Score (FAWCETT, 2006). O cálculo destas métricas foi implementado utilizando a biblioteca Scikit-learn (PEDREGOSA et al., 2011). Adicionalmente, para uma análise mais granular dos padrões de erro e acerto do classificador, foi gerada uma matriz de confusão, detalhando as predições para cada classe. A avaliação foi complementada por uma análise qualitativa, por meio da inspeção visual de amostras das imagens testadas, comparando suas classes reais com as classes preditas pelo modelo.

5 Resultados

Neste capítulo, são apresentados os resultados obtidos pelo modelo VGG16 na tarefa de classificação de doenças em folhas de cajueiro.

5.0.1 Análise Quantitativa do Desempenho

O desempenho geral do modelo foi sintetizado em um relatório de classificação, apresentado na Tabela 2. O modelo alcançou uma acurácia global de 90,0%, indicando um alto índice de acertos na distinção entre as classes "Doente" e "Saudável".

Tabela 2 – Relatório de classificação do modelo

Classe	Precisão	Recall	F1-Score
Doente	0,86	0,97	0,91
Saudável	0,97	0,84	0,90
Acurácia	0,90		

A análise das métricas por classe revela um comportamento estratégico do modelo. Para a classe "Doente", obteve-se um Recall excepcionalmente alto de 0,97. Este valor é importante para a aplicação agrícola, pois indica que o modelo foi capaz de identificar corretamente 97% de todas as folhas doentes, minimizando significativamente a ocorrência de falsos negativos. Em contrapartida, a Precisão de 0,86 sugere que, para atingir essa alta sensibilidade, o modelo ocasionalmente classifica folhas saudáveis como doentes (falsos positivos).

Para a classe "Saudável", o comportamento é inverso. A Precisão de 0,97 demonstra confiabilidade do modelo ao classificar uma folha como saudável, indicando uma baixa taxa de falsos positivos para esta classe. O Recall de 0,84, por sua vez, é o reflexo direto da alta sensibilidade para a classe "Doente", mostrando que 16% das folhas saudáveis foram incorretamente classificadas como doentes. Os valores de F1-Score, 0,91 para "Doente" e 0,90 para "Saudável", indicam um bom equilíbrio entre Precisão e Recall em ambas as classes.

5.0.2 Análise Qualitativa das Predições

Para ilustrar o comportamento descrito pelas métricas, foram analisadas amostras visuais das predições do modelo. A Figura 10 e a Figura 11 exemplificam casos de acerto (verdadeiro negativo e verdadeiro positivo, respectivamente), confirmando a capacidade do modelo de aprender características distintivas de ambas as classes. A correta identificação da folha doente na Figura 11 é um resultado prático do alto recall de 97% para essa classe.

Top 3 - Saudável Classificado como Saudável



Figura 10 – Imagem saudável classificado como saudável

Top 3 - Doente Classificado como Doente

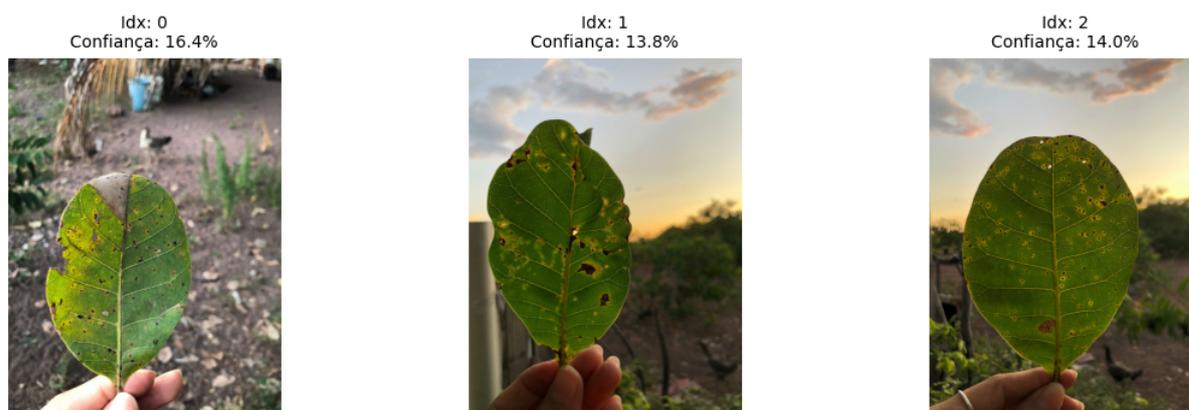


Figura 11 – Imagem doente classificado como doente

Por outro lado, os erros de classificação também foram examinados. A Figura 12 apresenta um falso negativo, onde uma folha doente foi erroneamente classificada como saudável. Este tipo de erro, embora minimizado pela alta sensibilidade do modelo, é o mais crítico no contexto fitossanitário. Já a Figura 13 ilustra um falso positivo, no qual uma folha saudável foi classificada como doente. Este erro, justificado pela precisão de 86% na classe "Doente", é geralmente considerado menos prejudicial, embora possa levar a intervenções desnecessárias.

Top 3 - Doente Classificado como Saudável (Erro)

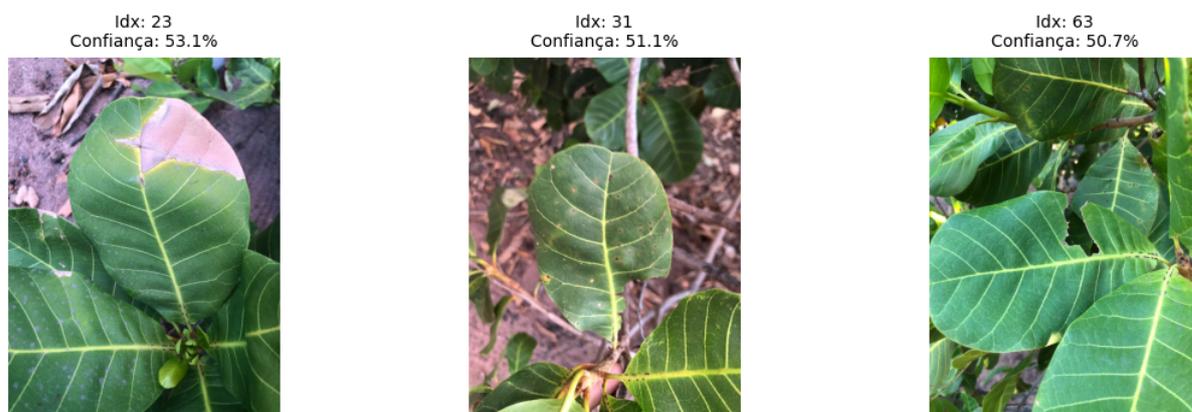


Figura 12 – Imagem Doente classificado como saudável

Top 3 - Saudável Classificado como Doente (Erro)



Figura 13 – Imagem saudável classificado como doente

6 Discussão

Nesta seção, o desempenho do modelo VGG16 desenvolvido neste estudo é contextualizado por meio de uma análise comparativa com os resultados de outros trabalhos relevantes da literatura que abordam a detecção de doenças em plantas. A Tabela 3 sumariza os principais achados.

Tabela 3 – Desempenho dos Modelos na Detecção de Doenças em Plantas

Trabalhos	Arquitetura	Precisão (%)	Recall (%)	F1-Score (%)	Acurácia (%)
Abbas	ResNet	85,0	–	86,3	94,4
Harakannanavar	Arqu. pers.	99,0	99,5	98,8	99,0
Rajagopal	MobileNetV2	99,2	–	–	–
Ouhami	Arqu. pers.	–	–	–	97,5
Vidhya	YOLOv5	92,6	90,9	92,4	–
Kazi	Arqu. pers.	85,9	–	–	–
Este trab.	VGG16 (Doente)	86,0	97,0	91,0	–
	VGG16 (Saudável)	97,0	84,0	90,0	90,0

A análise comparativa permite posicionar os resultados deste trabalho no contexto mais amplo da literatura. O estudo de Abbas, utilizando a arquitetura ResNet, alcançou uma acurácia superior (94,4%), porém com uma precisão para a classe doente ligeiramente inferior à nossa (85,0% vs. 86,0%). Mais notavelmente, nosso modelo obteve um recall de 97,0%, indicando uma sensibilidade muito maior na detecção de folhas doentes em comparação ao F1-Score de 86,3

Os trabalhos de Harakannanavar e Rajagopal apresentam os valores de precisão mais elevados, com 99,0% e 99,2%, respectivamente. O modelo de Harakannanavar, uma arquitetura personalizada, demonstrou um desempenho excepcional em todas as métricas. O modelo de Rajagopal, por sua vez, foca na precisão, mas não reporta outras métricas, o que dificulta uma análise completa sobre o equilíbrio do modelo. Da mesma forma, Ouhami e Kazi apresentam resultados de acurácia (97,5%) e precisão (85,9%) com arquiteturas personalizadas, mas sem detalhamento das demais métricas.

Em relação a Vidhya, que utilizou a arquitetura YOLOv5, observa-se que, embora sua precisão (92,6%) e F1-Score (92,4%) sejam superiores, nosso modelo demonstrou um recall consideravelmente maior (97,0% vs. 90,9%). Isso significa que nossa abordagem foi mais eficaz em minimizar a não detecção de folhas doentes (falsos negativos), um aspecto de grande importância prática em cenários agrícolas.

Em síntese, a comparação evidencia que, embora algumas arquiteturas na literatura apresentem métricas isoladas superiores especialmente em precisão e acurácia, o modelo VGG16 deste trabalho demonstra um excelente balanço e, crucialmente, o maior recall entre os trabalhos que reportaram essa métrica. Este elevado recall para a classe "doente" é

o principal diferencial da nossa abordagem, para cenários onde a falha na detecção de uma patologia pode ter consequências significativas. Portanto, os resultados validam a eficácia da abordagem para a classificação de folhas de cajueiro, com um desempenho alinhado e, em aspectos críticos como a sensibilidade, superior ao de outros estudos da área.

Apesar dos resultados promissores, é importante reconhecer as limitações do presente estudo para contextualizar sua aplicabilidade. O tamanho reduzido da base de dados, composta por apenas 100 imagens, pode restringir a capacidade de generalização do modelo, especialmente em cenários com variações não representadas no conjunto de treinamento. Adicionalmente, a ocorrência de falsos negativos, nos quais folhas doentes foram classificadas erroneamente como saudáveis, representa um desafio crítico, uma vez que falhas na detecção precoce podem favorecer a disseminação de doenças.

7 Conclusão

Este estudo valida a eficácia da visão computacional e do aprendizado profundo como uma ferramenta viável para a identificação automatizada de patologias em folhas de ca-juero, como a antracnose, gomose, mancha bacteriana e oídio. O trabalho demonstra que é possível superar as limitações de custo e especialização dos métodos de detecção tradicionais, estabelecendo uma metodologia que serve como um passo fundamental para o desenvolvimento de soluções de baixo custo na agricultura de precisão.

O principal achado desta pesquisa é que o modelo proposto, baseado na arquitetura VGG16, foi estrategicamente otimizado para alta sensibilidade na detecção de doenças. A capacidade do sistema de identificar a grande maioria das folhas doentes, minimizando a ocorrência de falsos negativos, é a sua característica mais valiosa do ponto de vista fitossanitário. Essa alta sensibilidade é importante para o manejo agrícola, pois garante a detecção precoce dos focos de infecção, permitindo intervenções mais rápidas e eficazes para conter a disseminação de doenças.

Uma contribuição significativa do trabalho foi a construção de um conjunto de dados próprio, com imagens coletadas em plantações do Piauí, preenchendo uma lacuna deixada pela ausência de bases públicas para este problema específico. Além disso, o estudo comprova que a técnica de aprendizado por transferência, aplicada a uma arquitetura clássica como a VGG16 e combinada com o aumento de dados, é uma abordagem eficiente e replicável para se obter resultados robustos, mesmo diante de um conjunto de dados limitado.

Como direcionamento para o futuro, a pesquisa aponta duas vias prioritárias. A primeira é a ampliação e diversificação do conjunto de dados, incorporando maior variabilidade de sintomas, cultivares e condições ambientais para aprimorar a capacidade de generalização do modelo. A segunda consiste na exploração de outras arquiteturas de redes neurais profundas, em uma investigação comparativa que busque otimizar não apenas a precisão, mas também a eficiência computacional, visando o desenvolvimento de uma ferramenta para o produtor rural.

Referências

- ABBAS, A. et al. Drones in plant disease assessment, efficient monitoring, and detection: a way forward to smart agriculture. *Agronomy*, MDPI, v. 13, n. 6, p. 1524, 2023. Citado 2 vezes nas páginas 22 e 24.
- AGUIAR, J. et al. Zoneamento pedoclimático para a cultura do cajueiro (*anacardium occidentale* l.) na região nordeste do brasil e no norte de minas gerais. *Revista Brasileira de Agrometeorologia*, v. 9, n. 3, p. 557–563, 2001. Citado na página 14.
- ALMEIDA, R. H.; CORSO, D. A.; JR, A. S. B. Visão computacional-sistemas de visão aplicados à inspeção industrial. *Anais do ENETEC*, 2007. Citado na página 17.
- Associação de Engenheiros Agrônomos de Sergipe (AEASE). *IBGE e Embrapa anunciam números da safra 2022 de caju*. 2023. Acesso em: 3 jun. 2025. Disponível em: <<https://www.aease.org.br/?p=3556>>. Citado na página 14.
- BISHOP, C. M.; NASRABADI, N. M. *Pattern recognition and machine learning*. [S.l.]: Springer, 2006. Citado na página 22.
- DING, X. et al. Repvgg: Making vgg-style convnets great again. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. [S.l.: s.n.], 2021. p. 13733–13742. Citado 2 vezes nas páginas 9 e 27.
- FAWCETT, T. An introduction to roc analysis. *Pattern recognition letters*, Elsevier, v. 27, n. 8, p. 861–874, 2006. Citado na página 28.
- FILHO, E. T. Inteligência artificial e direitos da personalidade: uma contradição em termos? *Revista da Faculdade de Direito, Universidade de São Paulo*, v. 113, p. 133–149, 2018. Citado na página 19.
- GAMA, M. A. S. et al. O cajueiro e suas fitobacterioses: Mancha angular e mancha de xanthomonas. *Anais da Academia Pernambucana de Ciência Agrônômica*, v. 10, p. 123–142, jun. 2015. Disponível em: <<https://www.journals.ufrpe.br/index.php/apca/article/view/394>>. Citado na página 14.
- GONÇALVES, J. I. Inteligência artificial e suas aplicações na indústria petrolífera. *SEMPESq-Semana de Pesquisa da Unit-Alagoas*, n. 8, 2020. Citado na página 19.
- GONZALEZ, R. C.; WOODS, R. E. *Processamento de imagens digitais*. [S.l.]: Editora Blucher, 2000. Citado na página 18.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep learning*. [S.l.]: MIT press, 2016. Citado na página 19.
- HARAKANNANAVAR, S. S. et al. Plant leaf disease detection using computer vision and machine learning algorithms. *Global Transitions Proceedings*, Elsevier, v. 3, n. 1, p. 305–310, 2022. Citado 2 vezes nas páginas 22 e 24.
- HART, P. E.; STORK, D. G.; WILEY, J. *Pattern classification*. Toronto: John Wiley & amp, 2001. Citado na página 28.

- HAWERROTH, M. et al. Busca por fontes de resistência a doenças de importância na cultura do cajueiro com base no comportamento de progênies. Fortaleza: Embrapa Agroindústria Tropical, 2017., 2017. Citado na página 16.
- KAZI, S. et al. Fruit grading, disease detection, and an image processing strategy. *Journal of Image Processing and Artificial Intelligence*, v. 9, n. 2, p. 17–34, 2023. Citado 2 vezes nas páginas 22 e 24.
- LIBRALÃO, G. L. et al. Técnicas de aprendizado de máquina para análise de imagens oftalmológicas. São Paulo. Universidade de São Paulo, 2003. Citado na página 19.
- MAHENDRAN, T. Symptom based disease detection on cashew plants using machine learning techniques. *NeuroQuantology*, NeuroQuantology, v. 21, n. 6, p. 1458, 2023. Citado na página 14.
- MARQUES, E. A. L. Estudo sobre redes neurais de aprendizado profundo com aplicações em classificação de imagens. 2016. Citado na página 20.
- MILANO, D. de; HONORATO, L. B. Visão computacional. *Faculdade de Tecnologia, Universidade Estadual de Campinas*, 2010. Citado na página 17.
- MILANO, D. de; HONORATO, L. B. Visao computacional. *UNICAMP Universidade Estadual de Campinas FT Faculdade de Tecnologia*, 2014. Citado na página 18.
- MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. *Sistemas inteligentes-Fundamentos e aplicações*, v. 1, n. 1, p. 32, 2003. Citado na página 19.
- MONTEIRO, F. et al. Tracking cashew economically important diseases in the west african region using metagenomics. *Frontiers in Plant Science*, Frontiers, v. 6, p. 141812, 2015. Citado na página 14.
- OUHAMI, M. et al. Computer vision, iot and data fusion for crop disease detection using machine learning: A survey and ongoing research. *Remote Sensing*, MDPI, v. 13, n. 13, p. 2486, 2021. Citado 2 vezes nas páginas 23 e 24.
- PAIVA, J. R. de; CRISÓSTOMO, J. R.; BARROS, L. d. M. Recursos genéticos do cajueiro: coleta, conservação, caracterização e utilização. Fortaleza: Embrapa Agroindustria Tropical, 2003., 2003. Citado na página 16.
- PARLINDO, F.; TONDOK, E.; WIYONO, S. Etiology of white root disease of cashew (*anacardium occidentale* l.). In: IOP PUBLISHING. *IOP Conference Series: Earth and Environmental Science*. [S.l.], 2022. v. 974, n. 1, p. 012007. Citado na página 15.
- PEDREGOSA, F. et al. Scikit-learn: Machine learning in python. *the Journal of machine Learning research*, JMLR. org, v. 12, p. 2825–2830, 2011. Citado na página 28.
- RAJAGOPAL, M. K.; MS, B. M. Artificial intelligence based drone for early disease detection and precision pesticide management in cashew farming. *arXiv preprint arXiv:2303.08556*, 2023. Citado 2 vezes nas páginas 23 e 24.
- REDMON, J. et al. You only look once: Unified, real-time object detection. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 779–788. Citado na página 23.

REHEM, A.; TRINDADE, F. H. V. Técnicas de visão computacional para rastreamento de olhar em vídeos. *Publicado em*, v. 3, n. 02, 2009. Citado na página 17.

RUDEK, M.; COELHO, L. d. S.; JR, O. C. Visão computacional aplicada a sistemas produtivos: fundamentos e estudo de caso. *XXI Encontro Nacional de Engenharia de Produção-2001, Salvador*, 2001. Citado na página 18.

SANDLER, M. et al. Mobilenetv2: Inverted residuals and linear bottlenecks. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2018. p. 4510–4520. Citado na página 23.

TEIXEIRA, G. R.; FERREIRA, V. M. Aplicações para agricultura de precisão: estimação de produção frutífera utilizando técnicas de visão computacional e aprendizagem de máquina. 2015. Citado na página 19.

VARGAS, A. C. G.; PAES, A.; VASCONCELOS, C. N. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. In: SN. *Proceedings of the xxx conference on graphics, patterns and images*. [S.l.], 2016. v. 1, n. 4. Citado 2 vezes nas páginas 9 e 20.

VIDHYA, N.; PRIYA, R. Automated diagnosis of the severity of tmb infestation in cashew plants using yolov5. *Journal of Image and Graphics*, v. 12, n. 3, 2024. Citado 2 vezes nas páginas 23 e 24.

WONNI, I. et al. Diseases of cashew nut plants (*anacardium occidentale* l.) in burkina faso. *Adv Plants Agric Res*, v. 6, n. 3, p. 00216, 2017. Citado 4 vezes nas páginas 9, 16, 17 e 18.

ZHANG, L.; WANG, S.; LIU, B. Deep learning for sentiment analysis: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, Wiley Online Library, v. 8, n. 4, p. e1253, 2018. Citado na página 20.



TERMO DE AUTORIZAÇÃO PARA PUBLICAÇÃO DIGITAL NA BIBLIOTECA “JOSÉ ALBANO DE MACEDO”

Identificação do Tipo de Documento

- () Tese
- () Dissertação
- (X) Monografia
- () Artigo

Eu, **Raglicia Sandi Ribeiro de Sousa**, autorizo com base na Lei Federal nº 9.610 de 19 de Fevereiro de 1998 e na Lei nº 10.973 de 02 de dezembro de 2004, a biblioteca da Universidade Federal do Piauí a divulgar, gratuitamente, sem ressarcimento de direitos autorais, o texto integral da publicação **Identificação de doenças no cajueiro usando visão computacional e processamento de imagens** de minha autoria, em formato PDF, para fins de leitura e/ou impressão, pela internet a título de divulgação da produção científica gerada pela Universidade.

Picos-PI 07 de Julho de 2025



Documento assinado digitalmente
RAGLICIA SANDI RIBEIRO DE SOUSA
Data: 07/07/2025 12:45:33-0300
Verifique em <https://validar.iti.gov.br>

Assinatura