

Trabalho de Licenciatura em
Informática

**Modelo de detecção e identificação de doenças
em plantas agrícolas baseadas em *machine
learning*: caso da mandioca**

Autor: Stanley Carmelita Aníbal Nhampossa

Maputo, 16 de Dezembro de 2025



FACULDADE DE CIÊNCIAS
Departamento de Matemática e Informática

Trabalho de Licenciatura em
Informática

**Modelo de detecção e identificação de doenças
em plantas agrícolas baseado em *machine*
learning: caso da mandioca**

Autor: Stanley Carmelita Aníbal Nhampossa

Supervisor: Prof. Doutor, Cachimo Combo Assane, UEM

Maputo, 16 de Dezembro de 2025

Dedicatória

O presente trabalho dedico a minha família, especialmente aos meus pais Aníbal Eduardo Nhampossa e Carmelita Luís Siavaca

Declaração de Honra

Declaro por minha honra que o presente Trabalho de Licenciatura é resultado da minha investigação e que o processo foi concebido para ser submetido apenas para a obtenção do grau de Licenciado em Informática, na faculdade de Ciências da Universidade Eduardo Mondlane.

Maputo, 16 de Dezembro de 2025

(Stanley Carmelita Aníbal Nhampossa)

Agradecimentos

O presente trabalho é resultado de muito esforço e dedicação, com a finalidade de obtenção do grau de Licenciatura no curso de Informática.

Agradeço, em primeiro lugar, à Faculdade de Ciências da Universidade Eduardo Mondlane, em especial ao corpo docente, pelo conhecimento transmitido e pela formação sólida que me foi proporcionada ao longo desta jornada académica.

Um agradecimento especial ao meu supervisor, Prof. Doutor Cachimo Combo Assane, pelo apoio constante, disponibilidade, paciência e valiosas orientações ao longo do desenvolvimento deste trabalho.

Agradeço, igualmente, a Deus, pela dádiva da vida, por ser a minha fonte de fé, inspiração e força ao longo de toda a caminhada. A Ele toda a honra e glória.

Aos meus pais, Aníbal Eduardo Nhampossa e Carmelita Luís Siavaca Nhampossa, agradeço profundamente pela educação, pelo amor incondicional e por todo o esforço e dedicação investidos na minha formação. Este marco também é fruto do vosso sacrifício.

Aos meus irmãos, Klayton, Anisley e Zoey Nhampossa, pela paciência, compreensão e apoio incondicional em todos os momentos.

A toda a minha família, amigos e colegas que, de forma directa ou indirecta, contribuíram para a minha formação pessoal e académica, deixo o meu sincero agradecimento. Em especial, expresso a minha gratidão a Deisy Hermínio, Alfredo Lemos, Muarucha Assane, Chantel Valoi, Hermon da Cruz, Malagy Cassimo, Herco Zauzau, António Sambo pelo apoio, incentivo e contributo ao longo desta caminhada.

A todos, o meu muito obrigado.

Resumo

Este trabalho aborda a detecção e identificação de doenças da mandioca utilizando técnicas de Machine Learning, contribuindo para a segurança alimentar e para a sustentabilidade do sector agrícola em Moçambique. A agricultura constitui um sector fundamental no contexto moçambicano, sendo responsável por aproximadamente 25% do Produto Interno Bruto (PIB) e empregando cerca de 70% da força laboral nacional, sobretudo pequenos agricultores. Contudo, a produção agrícola enfrenta desafios significativos devido à ocorrência de pragas e doenças, que podem provocar perdas de produção superiores a 50%, comprometendo o rendimento dos agricultores e a segurança alimentar.

Neste contexto, o trabalho propõe o uso de modelos de *machine learning* para a detecção precoce de doenças em folhas de mandioca, permitindo um diagnóstico mais rápido e eficiente, bem como a redução do uso indiscriminado de agrotóxicos. A pesquisa inclui a análise das principais doenças que afectam a cultura da mandioca, bem como o desenvolvimento e avaliação de modelos de Machine Learning adequados às condições específicas do contexto moçambicano.

Adicionalmente, foi desenvolvido um protótipo funcional seguindo uma abordagem ágil, com levantamento e priorização de requisitos, visando garantir uma aplicação prática voltada às necessidades dos agricultores. Os resultados obtidos demonstram o potencial do uso de técnicas de inteligência artificial na melhoria da precisão e rapidez do diagnóstico de doenças agrícolas, contribuindo para a modernização e sustentabilidade da agricultura em Moçambique.

Palavras-chave: Doença da mandioca, Rede neural convolucional, Doença em plantas, Agricultura de precisão, Moçambique

Abstract

This study addresses the detection and identification of cassava diseases using Machine Learning techniques, contributing to food security and the sustainability of the agricultural sector in Mozambique. Agriculture plays a fundamental role in the Mozambican context, accounting for approximately 25% of the Gross Domestic Product (GDP) and employing about 70% of the national workforce, particularly smallholder farmers. However, agricultural production faces significant challenges due to the occurrence of pests and diseases, which can lead to production losses exceeding 50%, compromising farmers' income and food security.

In this context, the study proposes the use of machine learning models for the early detection of diseases in cassava leaves, enabling faster and more efficient diagnosis, as well as reducing the indiscriminate use of agrochemicals. The research includes an analysis of the main diseases affecting cassava crops, along with the development and evaluation of Machine Learning models suitable for the specific conditions of the Mozambican context.

Additionally, a functional prototype was developed following an agile approach, including requirements gathering and prioritization, with the aim of providing a practical application tailored to farmers' needs. The obtained results demonstrate the potential of artificial intelligence techniques to improve the accuracy and speed of agricultural disease diagnosis, contributing to the modernization and sustainability of agriculture in Mozambique.

Keywords: Cassava disease, Convolutional neural network, Plant disease, Precision agriculture, Mozambique

Abreviaturas

API	Interface de Programação de Aplicação
CBSD	Listra Marrom
CMD	Mosaico da Mandioca
CNN	Redes Neurais Convolucionais
FAO	Organização das Nações Unidas para Agricultura e Alimentação
FN	Falsos Negativos
FP	Falsos Positivos
FAO	Organização das Nações Unidas para Agricultura e Alimentação
IA	Inteligência Artificial
IIAM	Instituto de Investigação Agrária de Moçambique
IITA	Internacional Institute of Tropical Agriculture
INE	Instituto Nacional de Estatística
KNN	K-Nearest Neighbors
MADER	Ministério da Agricultura e Desenvolvimento Rural
ML	<i>Machine Learning</i>
PDF	Formato de Documento Portátil
PEDSA II	Plano Estratégico de Desenvolvimento do Sector Agrário (2022 – 2030)
PCR	Reacção em Cadeia da Polimerase
PIB / GDP	Produto Interno Bruto
SGD	Gradiente Descendente Estocástico
RNA	Redes Neurais Artificiais
RT-PCR	Reacção em Cadeia da Polimerase com Transcrição Reversa
SI	Sistema de Informação

SVM	<i>Support Vector Machine</i>
TFLite	TensorFlow Lite
TN	Verdadeiros Negativos
TP	Verdadeiros Positivos
TIC	Tecnologias de Informação e Comunicação
ViT	<i>Vision Transformers</i>
XML	<i>Extensible Markup Language</i>
UML	Linguagem de Modelagem Unificada (<i>Unified Modeling Language</i>)

Índice

Dedicatória	i
Declaração de Honra	ii
Agradecimentos	iii
Resumo	iii
Abstract.....	v
Abreviaturas	vi
Lista de Figuras	xi
Lista de Tabelas.....	xiii
Introdução	1
1.1. Contextualização.....	1
1.2. Definição do Problema	3
1.3. Objectivos.....	4
1.3.1. Objectivos Gerais	4
1.3.2. Objectivos Específicos	4
1.4. Delimitação do Tema.....	4
1.5. Justificativa do Tema	4
1.6. Estrutura do Trabalho.....	6
Revisão de Literatura	8
2.1. Agricultura.....	8
2.2. Doenças em Plantas.....	9
2.3. Tecnologias Digitais na Agricultura.....	12
2.4. Processamento de Imagem e Visão Computacional.....	14
2.5. Inteligência Artificial e Machine Learning	15
2.5.1. Paradigmas de Aprendizagem.....	15
2.5.2. Generalização, Overfitting e Underfitting	16

2.5.3.	Formulação de Risco Empírico (Aprendizagem Supervisionada)	17
2.5.4.	Optimização e Early Stopping	18
2.5.5.	Redes Neurais Convolucionais (CNNs)	19
2.5.6.	Transfer Learning e Modelos Leves	19
2.5.7.	Regularização e Estratégias de Dados	20
2.5.8.	Validação e Metodologia Experimental	20
2.5.9.	Interpretabilidade e Incerteza	21
2.5.10.	Implicações para Agricultura	21
2.5.11.	Support Vector Machines (SVM)	22
2.5.12.	K-Nearest Neighbors (KNN)	22
2.6.	Machine Learning Aplicado à Agricultura	23
2.7.	Estudos Relevantes em África e Moçambique	24
2.8.	Síntese Crítica	25
	Material e Métodos	27
3.1.	Metodologia de pesquisa	27
3.1.1.	Quanto à Abordagem	27
3.1.2.	Quanto aos Objectivos	27
3.1.3.	Quanto à Natureza	28
3.1.4.	Quanto ao Método	28
3.1.5.	Justificação da Metodologia	28
3.2.	Materiais	29
3.2.1.	Base de Dados	29
3.2.2.	Ferramentas de Software	30
3.2.3.	Recursos Computacionais	30
3.2.4.	Ambiente de Implementação	31
3.3.	Etapas para o desenvolvimento do modelo de Machine Learning	31
3.3.1.	Colecta e Pré-processamento de Dados	31
3.3.2.	Modelagem	33
3.3.3.	Treino e Validação	33
3.3.4.	Medidas de Avaliação	35
3.3.5.	Exportação e Optimização do Modelo	36
3.4.	Métodos de Implementação	37

3.4.1. Visão Geral da Solução Proposta	37
3.4.2. Requisitos Funcionais.....	37
3.4.3. Requisitos Não Funcionais	38
3.4.4. Modelação e Arquitectura do Sistema.....	39
3.4.5. Tecnologias e Ferramentas Utilizadas	40
Experimentos e Resultados.....	42
4.1. Configuração dos Experimentos	42
4.1.1. Ambiente Computacional	42
4.1.2. Configuração dos Dados.....	42
4.1.3. Configuração dos Modelos e Parâmetros	43
4.1.4. Fluxo Experimental	44
4.2. Treino dos Modelos	44
4.2.1. Ambiente Computacional	45
4.2.2. CNN desenvolvida do zero	46
4.2.3. MobileNetV2 (Transfer Learning)	47
4.2.4. ResNet50 (Transfer Learning)	48
4.2.5. Controle de Overfitting e Reprodutibilidade.....	49
4.2.6. Saídas Esperadas e Análise dos Treinos.....	49
4.3. Resultados da Modelação e Avaliação.....	50
4.3.1. Resultados da Modelação	51
4.3.2. Medidas de Desempenho.....	52
4.3.3. Desempenho Comparativo entre os Modelos.....	52
4.3.4. Análise Detalhada por Classe.....	54
4.3.5. Interpretação dos Resultados.....	55
4.4. Resultados da Solução Desenvolvida	57
4.5. Discussão dos Resultados	60
Conclusões e Recomendações	64
5.1. Conclusões.....	64
5.2. Limitações e Recomendações	65
Referências Bibliográficas	67

Lista de Figuras

Figura 1: Exemplo de folhas de mandioca doentes - CMD.....	12
Figura 2: Fluxo do uso de TICs na agricultura – da recolha de dados em campo até ao suporte à decisão para o agricultor.....	13
Figura 3: Fluxo das etapas do processamento de imagens.....	14
Figura 4: fórmula matemática para a convolução discreta bidimensional.....	15
Figura 5: Representação esquemática dos paradigmas de aprendizagem em machine learning: supervisionada, não supervisionada e por reforço.....	16
Figura 6: Fórmula da representação do risco empírico regularizado	17
Figura 7: Fórmula da função Softmax	17
Figura 8: Fórmula da função de perda de entropia cruzada.....	17
Figura 9: Fluxo do treino supervisionado.....	18
Figura 10: Fórmula de actualização de parâmetros na descida do gradiente	18
Figura 11: Estrutura simplificada de um bloco residual (ResNet) e de uma convolução separável em profundidade (MobileNetV2).....	20
Figura 12: Mapa de calor gerado por Grad-CAM.....	21
Figura 13: Imagem de uma folha da mandioca	29
Figura 14: Arquitectura simplificada de uma CNN	31
Figura 15: Fluxo metodológico da pesquisa	31
Figura 16: Data augmentation aplicado a uma folha de mandioca.....	32
Figura 17: Arquitectura geral do modelo CNN proposto.....	33
Figura 18: Fórmula da acurácia.....	35
Figura 19: Fórmula da precisão	35
Figura 20: Fórmula de recall	35
Figura 21: Fórmula de F1 Score	36
Figura 22: Fluxo de exportação e optimização do modelo para mobile	37
Figura 23: Diagrama Entidade-Relacionamento	39
Figura 24: Diagrama de Sequeência	40
Figura 25: Curvas de acurácia e loss durante o treino e validação dos modelos: (a,d) CNN (do zero), (b,e) MobileNetV2, (c,f) ResNet50	51
Figura 26: Matriz de confusão obtida pela MobileNetV2	55
Figura 27: Tela inicial	57
Figura 28: Tela de nova análise.....	58
Figura 29: Tela de resultado da análise	59

Figura 30: Tela de apagar e partilhar análise.....	60
--	----

Lista de Tabelas

Tabela 1: Tabela do INE (2023) mostrando a variação da produção das culturas alimentares básicas (milho, mandioca, feijão, amendoim).....	9
Tabela 2: Principais doenças da mandioca, agentes causadores, sintomas e impacto.....	10
Tabela 3: Principais estudos internacionais e africanos sobre aplicação de machine learning na agricultura, com destaque para a detecção de doenças em plantas.....	24
Tabela 4: Tabela comparativa das Arquitecturas CNNs	34
Tabela 5: Requisitos Funcionais	37
Tabela 6: Requisitos não funcionais	38
Tabela 7: Desempenho comparativo das arquitecturas testadas.....	53

Introdução

Neste capítulo, faz-se a contextualização do tema, a descrição e definição do problema e dos objectivos que dão sentido ao presente trabalho. Na contextualização, aborda-se sobre o a agricultura em Moçambique, o impacto que tem sobre o impacto na economia do país e como os problemas relacionados a agricultura é abordada sobre ponto de vista da computação em Moçambique e no mundo.

1.1. Contextualização

Em Moçambique, a agricultura constitui-se como um dos pilares do desenvolvimento económico e da segurança alimentar, contribuindo com cerca de 25% do Produto Interno Bruto. Segundo o INE (2023), o sector agrícola continua a ter um papel expressivo na estrutura produtiva nacional.

O Banco Mundial (2024) reforça que a agricultura emprega aproximadamente 70% da população activa, sobretudo em zonas rurais, desempenhando um papel central na subsistência das famílias e na redução da pobreza. No entanto, este sector enfrenta grandes desafios, entre os quais a ocorrência frequente de doenças e pragas que afectam negativamente a produtividade. Muitas destas doenças, provocadas por fungos, bactérias, vírus ou factores ambientais, são de difícil diagnóstico precoce, o que contribui para perdas de produção que podem atingir até 50% em determinadas culturas e condições agrícolas (FAO, 2020).

Nas últimas décadas, o avanço da computação e, mais recentemente, da inteligência artificial (IA), tem aberto novas possibilidades para o diagnóstico precoce e automatizado de doenças agrícolas. Globalmente, diversos estudos têm explorado o uso de técnicas de *machine learning* e redes neurais convolucionais (CNNs) para classificar imagens de folhas doentes, com resultados promissores. Ferentinos (2018), por exemplo, demonstrou que modelos de *deep learning* podem atingir mais de 99% de precisão na identificação de doenças em plantas com base em imagens. Por outro lado, Picon et al. (2018) adaptaram CNNs para dispositivos móveis, facilitando o uso em campo.

Em África, iniciativas como a da PlantVillage, na Nigéria e no Quénia, têm utilizado modelos treinados com bases de dados internacionais para apoiar pequenos agricultores com diagnóstico via *smartphones*. Estes sistemas, alimentados por redes neurais e bases de dados como a PlantVillage Dataset (Hughes & Salathé, 2015), mostram o potencial de aplicação em realidades semelhantes à moçambicana.

Em Moçambique, contudo, ainda há escassez de soluções tecnológicas acessíveis e adaptadas às condições agroecológicas locais. Embora existam iniciativas pontuais ligadas à digitalização da agricultura, como o uso de plataformas móveis de extensão agrícola, sistemas de monitorização climática e ferramentas digitais de apoio ao agricultor, a aplicação directa de Inteligência Artificial para o diagnóstico de doenças em culturas como a mandioca ainda é incipiente. Estudos quantitativos locais que avaliem a prevalência e o impacto das doenças agrícolas em Moçambique continuam limitados em termos de cobertura nacional e aplicação de tecnologias avançadas. No entanto, alguns trabalhos relevantes já foram realizados. O *Digital Agriculture Country Study – Moçambique*, publicado pela CCARDESA, descreve os desafios estruturais enfrentados pelo sector agrícola moçambicano, destacando limitações na adopção de tecnologias modernas, fraca infraestrutura digital e reduzido acesso a ferramentas tecnológicas por parte dos pequenos agricultores (CCARDESA, 2022). O Instituto de Investigação Agrária de Moçambique (IIAM, 2019) também documentou perdas produtivas significativas associadas a pragas e doenças em culturas alimentares, com base em estudos de campo. Embora relevantes, esses trabalhos baseiam-se maioritariamente em abordagens tradicionais, o que reforça a necessidade de integrar soluções computacionais inovadoras e acessíveis, como a inteligência artificial, para o diagnóstico precoce e automatizado de doenças agrícolas. Estudos empíricos e revisões confirmam que doenças virais como o mosaico da mandioca (CMD) e a listra marrom (CBSD) têm elevada prevalência em regiões tropicais da África, com impacto directo na produtividade especialmente em zonas do norte de Moçambique. Uma revisão conduzida por Legg e Thresh (2000) mostra que essas doenças afectam severamente o rendimento das lavouras, sendo comumente diagnosticadas por observação visual, o que contribui para erros e atrasos no tratamento. Além disso, Toko (2007) realizou um levantamento fitossanitário em Moçambique utilizando inspecção de campo e amostragem empírica para documentar a distribuição e severidade de doenças na mandioca, mas sem empregar ferramentas tecnológicas. De forma complementar, Shirima et al. (2022) constataram nas Ilhas Comores que CMD estava presente em 95,5% dos campos visitados e CBSD em 83,3%, com validação laboratorial por reacção em cadeia da polimerase com transcrição reversa (RT-PCR) e sequenciamento. Esses estudos demonstram a recorrência das doenças foliares e a limitação dos métodos tradicionais de diagnóstico, reforçando a urgência na adopção de soluções computacionais mais acessíveis e automatizadas.

Dessa forma, este trabalho insere-se na intersecção entre a agricultura e a computação, propondo o desenvolvimento de um protótipo baseado em inteligência artificial para detecção e identificação automática de doenças foliares na mandioca, contribuindo para a redução do uso de agrotóxicos, melhoria na precisão do diagnóstico e aumento da produtividade agrícola. Ao integrar abordagens quantitativas com soluções computacionais modernas, pretende-se oferecer uma ferramenta útil e adaptada ao contexto nacional.

1.2. Definição do Problema

O surgimento de pragas e doenças em plantas agrícolas continua a ser uma das principais causas de perdas de produtividade em Moçambique, exigindo dos agricultores atenção redobrada na identificação e tratamento dessas enfermidades. Segundo Vasco e Dinar (2024), 15% dos agricultores moçambicanos relataram perdas directamente atribuídas a pragas e doenças, sendo esta a segunda maior preocupação após as secas (59%). Além disso, pragas específicas como a lagarta-do-cartucho (*Spodoptera frugiperda*) podem reduzir a produtividade do milho entre 21% e 53% (USDA, 2022), enquanto infestações durante o armazenamento de mandioca chegam a provocar perdas de até 80% (FAO, 2022). Esses números demonstram a relevância das doenças e pragas agrícolas no país e reforçam a urgência na adopção de soluções tecnológicas avançadas, como ferramentas de diagnóstico precoce e automatizado, para mitigar riscos em campo. Tradicionalmente, o diagnóstico é feito visualmente, o que requer conhecimento especializado e está sujeito a erros, atrasos e subjectividade. Como consequência, muitos agricultores recorrem ao uso indiscriminado de agrotóxicos, o que, além de aumentar os custos de produção, compromete a saúde das plantas, dos consumidores e do meio ambiente. Estudos recentes em Moçambique mostram que esse uso é frequentemente feito sem treinamento técnico nem equipamentos de protecção, como observado no distrito de Boane, onde pesticidas de elevada toxicidade continuam a ser aplicados em hortícolas (MANGUANA et al., 2025). Na província de Niassa, verificou-se um crescimento de 28% no consumo de insecticidas entre 2014 e 2015, evidenciando uma tendência de aumento no uso de químicos agrícolas (MALOA, 2023). Apesar desse cenário, iniciativas regulatórias já resultaram no cancelamento de 79 registos de pesticidas altamente perigosos (FAO, 2014).

Estudos como o de Picon et al. (2018) indicam que até 50% da produção agrícola pode ser comprometida por doenças não diagnosticadas a tempo. Nesse contexto, a rapidez e precisão no diagnóstico são fundamentais para a eficácia das medidas de controle e mitigação.

A Inteligência Artificial (IA), em particular através de técnicas de *Machine Learning* e *Deep Learning*, tem demonstrado potencial significativo para resolver esse tipo de problema, como mostram Ferentinos (2018) e Hughes & Salathé (2015). O uso de modelos de redes neurais convolucionais (CNNs) permite a análise automatizada de imagens de folhas, com alta precisão, promovendo diagnósticos mais rápidos e acessíveis.

Diante desse cenário, surge a seguinte pergunta de pesquisa: Até que ponto a aplicação de técnicas de Inteligência Artificial pode melhorar a precisão e a eficiência no diagnóstico de doenças em plantas

agrícolas, em comparação com os métodos tradicionais usados por pequenos agricultores em Moçambique?

1.3. Objectivos

1.3.1. Objectivos Gerais

Desenvolver modelo para detecção e identificação de doenças em plantas agrícolas baseado em *Machine Learning*.

1.3.2. Objectivos Específicos

- Descrever a prevalência de doenças em plantas agrícolas em Moçambique;
- Aplicar modelos de Machine Learning, como Redes Neurais Convolucionais (CNN), Support Vector Machines (SVM) e K-Nearest Neighbors (KNN), para a identificação de doenças em plantas agrícolas e propor aquele que melhor se ajusta às condições locais;
- Implementar e realizar testes do protótipo do modelo proposto.

1.4. Delimitação do Tema

Este trabalho está delimitado à aplicação de técnicas de inteligência artificial para a detecção e identificação de doenças foliares em plantas de mandioca (*Manihot esculenta*) em Moçambique, com ênfase na região sul do país, especificamente no distrito de Boane, província de Maputo. O foco principal será a classificação automática de imagens de folhas, considerando cinco classes: planta saudável, mosaico da mandioca, mancha bacteriana, listra marrom e mancha verde. A escolha desta área deve-se à relevância agrícola da mandioca no sul do país, à facilidade de acesso aos dados e à infraestrutura de teste local, bem como à viabilidade futura de implementação prática em campo com agricultores da região. A investigação será conduzida com base em imagens públicas de datasets internacionais, adaptando os modelos às condições agroecológicas locais. O estudo não incluirá a análise de doenças de raiz nem factores ambientais indirectos (como solo, clima ou pragas). A aplicação prática será demonstrada por meio de um modelo de rede neural convolucional (CNN), com potencial para uso em dispositivos móveis acessíveis aos pequenos agricultores.

1.5. Justificativa do Tema

A escolha da mandioca (*Manihot esculenta*) como foco deste trabalho justifica-se por múltiplos factores de ordem económica, social e técnica. A mandioca é uma das culturas alimentares mais importantes em Moçambique, servindo como fonte primária de subsistência para milhões de moçambicanos, especialmente em zonas rurais. Segundo a FAO (2021), trata-se de uma cultura estratégica para a

segurança alimentar do país, sustentando particularmente os pequenos agricultores. O Banco Mundial (2018) também reforça que a mandioca continua a ser um dos principais alimentos básicos em Moçambique, crucial para os meios de vida rurais. Dados recentes do INE (2023) mostram que, entre 2022 e 2023, a mandioca registou uma taxa de variação de 17,7% na produção, ficando atrás apenas do amendoim e acima de culturas tipo feijões, o que confirma sua relevância no cenário agrícola nacional. Além disso, Macondzo (2018), em sua dissertação de mestrado em Economia Agrária na Universidade Eduardo Mondlane, ressalta que a mandioca é uma das principais culturas alimentares praticadas pelos agregados familiares nas regiões Centro e Norte do país. A sua resistência à seca, facilidade de cultivo e versatilidade alimentar tornam-na estratégica para a segurança alimentar do país.

Contudo, a mandioca é altamente vulnerável a doenças foliares como o mosaico da mandioca, a mancha bacteriana, a listra marrom e a mancha verde. Segundo Legg e Thresh (2000), estas doenças representam algumas das principais limitações bióticas da cultura em África, podendo reduzir a produção em até 50%. A FAO (2019) também reforça que tais enfermidades comprometem seriamente o rendimento e a qualidade da mandioca produzida em países como Moçambique.

O diagnóstico destas doenças, por sua vez, é particularmente complexo. Ferentinos (2018) explica que os sintomas foliares podem ser facilmente confundidos com deficiências nutricionais ou com outras doenças, tornando o diagnóstico visual pouco confiável. De forma semelhante, Picon et al. (2018) observaram que, em condições de campo, a inspeção tradicional exige um nível de experiência técnica que frequentemente não está ao alcance dos pequenos agricultores. Além disso, a utilização excessiva ou inadequada de agrotóxicos como tentativa de contenção das doenças agrava os impactos ambientais e económicos.

Do ponto de vista técnico-científico, a escolha da mandioca também é justificada pela disponibilidade de datasets públicos internacionais, como o *PlantVillage Dataset* (Hughes & Salathé, 2015), que contém imagens anotadas de folhas saudáveis e doentes de mandioca. Isso possibilita a aplicação e validação de modelos de aprendizado profundo com dados já estruturados, o que é essencial para estudos de classificação automática.

A nível internacional, trabalhos como os de Ferentinos (2018) e Picon et al. (2018) demonstram que modelos de redes neurais convolucionais (CNNs) são eficazes na identificação de doenças em plantas com elevada precisão, podendo ser aplicados inclusive em dispositivos móveis. No contexto africano, iniciativas como a do PlantVillage Nuru, promovida na Nigéria e no Quênia, já usam tecnologia semelhante para apoiar pequenos produtores.

Em Moçambique, entretanto, observa-se uma lacuna significativa no uso de tecnologias de inteligência artificial voltadas à agricultura, particularmente no diagnóstico automatizado de doenças específicas como as da mandioca. Assim, este trabalho propõe-se a contribuir para a redução dessa lacuna, explorando soluções computacionais acessíveis e eficazes, com potencial de aplicação prática em campo, adaptadas às condições agroecológicas do país.

Dessa forma, o estudo é relevante tanto pela viabilidade técnica quanto pelo potencial impacto social, contribuindo para o aumento da produtividade, redução de perdas agrícolas e uso mais racional de insumos, promovendo a sustentabilidade no sector agrícola moçambicano.

1.6. Estrutura do Trabalho

O presente trabalho é composto por cinco (5) capítulos, nomeadamente: Introdução, Revisão da Literatura, Material e Métodos, Experimentos e Resultados, Conclusão e Recomendações, e uma (1) secção não numerada, composta por Referências Bibliográficas. Abaixo, segue a descrição de cada um dos capítulos:

- No **capítulo I**, que se refere à **Introdução**, é dada uma visão geral sobre o tema a ser explorado no trabalho. Neste capítulo, é feita a contextualização do tema, a definição do problema, são apresentados os objectivos do trabalho e a estrutura do mesmo.
- No **capítulo II**, que se refere à **Revisão da Literatura**, são abordados os conceitos dos termos relativos ao tema, a fim de deixar o leitor familiarizado com o tema e com o ambiente em que se desenvolve o trabalho.
- No **capítulo III**, que se refere à **Material e Métodos**, são apresentados os procedimentos técnicos e as ferramentas usadas para alcançar os objectivos traçados para o trabalho.
- No **capítulo IV**, que se refere à **Experimentos e Resultados**, apresenta-se os resultados obtidos da aplicação do modelo proposto e discussão dos mesmos de forma comparativa com alguns estudos disponíveis.
- No **capítulo V**, que se refere à **Conclusão e Recomendações**, são apresentadas as conclusões que foram tiradas a partir da realização do trabalho, as limitações e recomendações para futuras pesquisas relacionadas com o tema.
- Secção das Referências Bibliográficas – tratando-se de um trabalho de estudo científico, é necessário fazer estudos bibliográficos com objectivo de aprimorar o trabalho. Portando,

nesta secção são apresentadas as obras bibliográficas apresentadas neste trabalho que culminou na realização do mesmo.

Revisão de Literatura

A revisão de literatura tem como finalidade situar o presente estudo no estado actual do conhecimento, destacando conceitos, teorias e investigações relacionadas. No caso desta pesquisa, o foco recai sobre a aplicação de técnicas de *machine learning* na agricultura, com ênfase na detecção de doenças da mandioca, cultura de grande relevância para a segurança alimentar em Moçambique. Assim, serão abordados temas como agricultura e segurança alimentar, doenças em plantas, tecnologias digitais, processamento de imagens, visão computacional, inteligência artificial e aplicações práticas em diferentes contextos, incluindo estudos internacionais, africanos e nacionais.

2.1. Agricultura

A agricultura constitui a base da economia moçambicana, representando não apenas a principal fonte de subsistência da população rural, mas também um dos maiores contributos para o Produto Interno Bruto (PIB) nacional (INE, 2023).

Entre as culturas alimentares de maior relevância destacam-se o milho, a mandioca, o feijão e o amendoim, que asseguram a dieta básica da maioria das famílias (Macondzo, 2018). Dados recentes do Instituto Nacional de Estatística mostram ainda que, entre 2022 e 2023, o amendoim registou um crescimento de 98,4% na produção, a mandioca uma variação de 17,7% e os feijões um aumento de 16,9% (INE, 2023). Estes números confirmam a relevância da mandioca não apenas como alimento de subsistência, mas também como cultura estratégica para a estabilidade da produção agrícola nacional.

No que respeita à segurança alimentar, a Organização das Nações Unidas para a Agricultura e Alimentação define-a como a garantia de que todas as pessoas tenham, em todo o momento, acesso físico, económico e social a alimentos suficientes, seguros e nutritivos (FAO, 2020). Nesse contexto, a mandioca assume um papel fundamental pela sua resistência à seca, facilidade de cultivo e versatilidade alimentar, é considerada essencial para a estabilidade alimentar do país. A FAO (2021) reforça que se trata de uma cultura estratégica para a África Austral, enquanto o Banco Mundial (2018) sublinha que, em Moçambique, a mandioca continua a ser um dos principais alimentos básicos, crucial para a subsistência das famílias rurais.

Ainda assim, a segurança alimentar em Moçambique enfrenta desafios significativos, incluindo mudanças climáticas, instabilidade nos preços agrícolas e, sobretudo, o impacto das doenças que afectam as

principais culturas, como é o caso da mandioca. Estes factores comprometem a disponibilidade e o acesso aos alimentos. O Instituto de Investigação Agrária de Moçambique documenta perdas produtivas severas associadas a pragas e doenças (IIAM, 2019). A FAO (2022) estima que, em alguns casos, estas perdas podem atingir até 50% da produção agrícola, reforçando a urgência da adopção de soluções inovadoras para monitorar e proteger a produção agrícola.

Tabela 1: Tabela do INE (2023) mostrando a variação da produção das culturas alimentares básicas (milho, mandioca, feijão, amendoim)

Cultura	2019	2020	2021	2022	2024	Taxa de Variação (%) 2023/2022
Arroz	179 836	175 322	206 115	245 277	161 920	-34,0
Milho	1 451 686	1 632 321	1 824 281	2 382 511	2 124 749	-10,8
Mapira	158 192	142 002	146 633	149 566	139 553	-6,7
Mexoeira	40 545	22 099	22 830	23 515	17 099	-27,3
Amendoim	151 220	102 958	111 924	114 162	226 498	98,4
Mandioca	6 019 200	6 025 663	6 218 141	6 466 857	7 610 852	17,7
Batata doce	509 385	448 633	495 377	510 238	459 805	-9,9
Feijões	399 511	325 872	415 828	469 889	549 153	16,9

Fonte: Extraída do documento de Indicadores Básicos de Agricultura e Alimentação elaborado pelo MADER

2.2. Doenças em Plantas

As doenças em plantas constituem um dos principais factores que comprometem a produtividade agrícola e, consequentemente, a segurança alimentar em países em desenvolvimento. Segundo Lopes e Ávila (2005), as doenças são resultantes da interação entre hospedeiro, patógeno e ambiente, podendo ser causadas por fungos, bactérias, vírus ou factores fisiológicos.

O impacto económico das doenças agrícolas é significativo. Carollo (2016) destaca que estas enfermidades podem reduzir a qualidade e a quantidade da produção agrícola, com reflexos directos na renda do agricultor. De acordo com Savary et al. (2019), as doenças agrícolas continuam entre as principais causas de perdas globais de produção, podendo reduzir entre 10% e 40% do rendimento das principais culturas alimentares, com valores superiores a 50% em culturas particularmente vulneráveis. Estudos recentes confirmam que esses impactos permanecem significativos, sobretudo em países em desenvolvimento, onde o acesso a diagnóstico precoce é limitado (Bebber, 2022). Além das perdas

económicas, estas enfermidades afectam a disponibilidade de alimentos, a renda dos agricultores e a estabilidade das cadeias de valor agrícolas.

No caso da mandioca (*Manihot esculenta*), cultura de grande importância para a segurança alimentar e a subsistência rural em Moçambique, a sua relevância tem sido amplamente reconhecida em estudos nacionais e internacionais. A FAO (2022) identifica a mandioca como uma das principais culturas alimentares do país, essencial para a dieta das famílias rurais. Dados do INE (2023) reforçam esta centralidade ao indicar que a mandioca figura entre as culturas básicas com maior peso na produção agrícola nacional. De forma complementar, Macondzo (2018) destaca que a mandioca é uma das culturas predominantes praticadas pelos agregados familiares nas regiões Centro e Norte do país.

Em termos fitossanitários, quatro doenças foliares assumem particular destaque:

- **Doença do Mosaico da Mandioca (CMD – Cassava Mosaic Disease):** causada por vírus do género *Begomovirus*, transmitidos pela mosca-branca (*Bemisia tabaci*). Provoca folhas deformadas e manchadas, reduzindo drasticamente a fotossíntese.
- **Doença da Estria Castanha da Mandioca (CBSD – Cassava Brown Streak Disease):** causada por vírus da família *Potyviridae*, compromete as raízes tuberosas, tornando-as impróprias para o consumo.
- **Mancha bacteriana:** provocada por bactérias do género *Xanthomonas*, resulta em necroses foliares e enfraquecimento da planta.
- **Mancha verde:** doença foliar caracterizada por manchas escuras e perda de vigor.

Tabela 2: Principais doenças da mandioca, agentes causadores, sintomas e impacto

Doença	Agente causador	Sintomas principais	Impacto na produção
Mosaico da Mandioca (CMD)	Vírus do género <i>Begomovirus</i> transmitidos pela mosca-branca (<i>Bemisia tabaci</i>)	Folhas deformadas, enrugadas e com manchas cloróticas (em mosaico), redução da fotossíntese	Redução drástica da produtividade; pode levar a perdas superiores a 80% em surtos severos
Estria Castanha da Mandioca (CBSD)	Vírus da família <i>Potyviridae</i>	Estrias marrons nas nervuras, necrose das raízes tuberosas, tornando-as impróprias para consumo	Compromete a qualidade e comercialização da raiz; perdas de 30–50% são comuns

Mancha Bacteriana	Bactérias do gênero <i>Xanthomonas</i>	Necroses escuras nas folhas, murcha e queda prematura	Enfraquecimento da planta; redução do rendimento e da longevidade das lavouras
Mancha Verde	Patógenos diversos associados a factores ambientais	Manchas escuras difusas, diminuição da área fotossintética	Redução do vigor da planta e queda gradual na produção

Fonte: Adaptado de Lopes & Ávila (2005); Carollo (2016); Picon et al. (2018); Ramcharan et al. (2017).

A identificação dessas doenças é tradicionalmente realizada por inspecção visual em campo. No entanto, este método depende fortemente da experiência do técnico e está sujeito a erros de interpretação. Ramcharan et al. (2017) enfatizam que, em regiões rurais da África, a falta de especialistas dificulta ainda mais a detecção precoce.

Outro método utilizado é a análise laboratorial, especialmente quando os sintomas observados em campo não são conclusivos. Legg e Thresh (2000) descrevem que, no caso das doenças virais da mandioca, a confirmação do diagnóstico pode requerer técnicas laboratoriais específicas. Em estudos posteriores, Hillocks e Jennings (2003) também destacam o uso de métodos moleculares, como a PCR, para identificar com precisão a presença dos vírus associados à doença da estria castanha. Embora mais precisos, estes processos são dispendiosos e de difícil acesso para pequenos agricultores moçambicanos. Nesse cenário, torna-se fundamental o desenvolvimento de métodos automatizados de detecção precoce, capazes de apoiar agricultores na tomada de decisões rápidas e eficientes, mitigando perdas de produtividade e fortalecendo a segurança alimentar.



Figura 1: Exemplo de folhas de mandioca doentes - CMD

Fonte: Extraída do dataset do Kaggle

2.3. Tecnologias Digitais na Agricultura

O avanço das tecnologias digitais tem transformado o sector agrícola, introduzindo soluções inovadoras que permitem maior eficiência no uso de recursos e melhor gestão da produção. O uso das Tecnologias de Informação e Comunicação (TICs) na agricultura tem adquirido um papel estratégico na modernização do sector, facilitando a recolha, análise e disseminação de dados relevantes para apoiar a tomada de decisão em diferentes etapas do ciclo produtivo. A FAO (2022) destaca que tecnologias digitais como aplicações móveis, sensoriamento remoto, drones e plataformas de gestão agrícola têm contribuído para melhorar a eficiência e a resiliência dos sistemas produtivos. De forma semelhante, estudos recentes do Banco Mundial evidenciam que as TICs têm permitido um acesso mais rápido à informação agronómica, fortalecendo a capacidade dos agricultores de responder a riscos climáticos e fitossanitários (World Bank, 2021). No contexto moçambicano, o relatório *Digital Agriculture Country Study* identifica que as TICs estão

a ganhar relevância crescente, especialmente em iniciativas de monitorização, extensão rural e apoio à produção agrícola (CCARDESA, 2022).

Em particular, os sistemas de monitoramento remoto, baseados em sensores, drones e imagens de satélite, têm sido amplamente utilizados para acompanhar o crescimento das culturas, identificar áreas de estresse hídrico e detectar sinais iniciais de pragas ou doenças. Estes recursos reduzem a dependência exclusiva da inspecção visual em campo e aumentam a precisão das intervenções.

No contexto africano, iniciativas como o PlantVillage Nuru, desenvolvido no Quênia e na Nigéria, demonstram o potencial dos aplicativos móveis para apoiar agricultores familiares. O sistema utiliza algoritmos de *machine learning* integrados em dispositivos móveis para identificar doenças em plantas a partir de fotografias das folhas (Ramcharan, 2019). Esse tipo de solução mostra como ferramentas digitais podem democratizar o acesso a diagnósticos rápidos e de baixo custo.

Em Moçambique, o uso de TICs na agricultura ainda enfrenta desafios significativos. O Plano Estratégico para o Desenvolvimento do Sector Agrário (PEDSA II 2022–2030), elaborado pelo Ministério da Agricultura e Desenvolvimento Rural, reconhece que a digitalização agrícola é essencial para aumentar a produtividade e resiliência do sector. Contudo, também aponta limitações, como a fraca infraestrutura de conectividade em zonas rurais, o acesso restrito a dispositivos móveis e a carência de soluções adaptadas ao contexto local (MADER, 2022).

Apesar disso, algumas iniciativas locais já ilustram o potencial das tecnologias digitais. Um exemplo é o projecto ThirdEye, que utilizou drones para monitorar campos agrícolas nas províncias do sul, permitindo identificar precocemente áreas afectadas por pragas e estresse hídrico (FutureWater, 2017). Outro caso relevante é a criação do Laboratório Internacional de Agricultura Digital, em parceria entre a Universidade Eduardo Mondlane e instituições internacionais, que visa aplicar inteligência artificial e análise de dados para enfrentar desafios agrícolas nacionais (UEM, 2023).

Estas experiências, embora ainda incipientes, demonstram que o país possui espaço para expandir o uso de soluções digitais na agricultura. As limitações actuais representam, ao mesmo tempo, uma oportunidade para o desenvolvimento de ferramentas de baixo custo, optimizadas para pequenos agricultores. A FAO (2022) destaca que aplicações móveis integradas a modelos de *machine learning* podem contribuir para reduzir perdas agrícolas, reforçar a resiliência das comunidades rurais e fortalecer a segurança alimentar em Moçambique.



Figura 2: Fluxo do uso de TICs na agricultura – da recolha de dados em campo até ao suporte à decisão para o agricultor.

Fonte: Elaborado pelo autor

2.4. Processamento de Imagem e Visão Computacional

O processamento de imagens é uma área da ciência da computação que trata da aquisição, manipulação e análise de imagens digitais, com o objectivo de extrair informações úteis. Segundo Maregoni (2009), esse processo envolve etapas como a melhoria da qualidade da imagem, a segmentação de regiões de interesse e a extração de características relevantes para posterior classificação.

A visão computacional, por sua vez, busca permitir que máquinas interpretem imagens de forma semelhante à percepção humana. Marr (1982) descreve a visão computacional como uma disciplina que combina algoritmos matemáticos e modelos computacionais para analisar a estrutura e o conteúdo de imagens.

De maneira geral, o *pipeline* de processamento de imagens aplicado à agricultura pode ser dividido em quatro fases principais:

- i. **Aquisição da imagem** – por meio de câmeras digitais, drones ou sensores móveis;
- ii. **Pré-processamento** – incluindo normalização, redução de ruído e ajustes de iluminação;
- iii. **Extração de características** – identificação de padrões, texturas, bordas ou cores associadas a sintomas de doenças;
- iv. **Classificação** – utilização de algoritmos de *machine learning* ou *deep learning* para determinar a classe da imagem (saudável ou doente).




Figura 3: Fluxo das etapas do processamento de imagens

Fonte: Elaborado pelo autor, com base em Maregoni (2009), Marr (1982) e Ferentinos (2018)

Um dos pontos centrais na classificação é a representação matemática das características extraídas das imagens. A detecção de bordas, por exemplo, pode ser realizada por meio da aplicação de filtros

convolucionais que realçam variações locais de intensidade, abordagem amplamente documentada no campo do processamento digital de imagens (Gonzalez & Woods, 2018), cuja formulação genérica é dada pela convolução entre a matriz da imagem $I(x, y)$ e o kernel K :

$$S(x, y) = (I * K)(x, y) = \sum_m \sum_n I(m, n) \cdot K(x - m, y - n)$$

Figura 4: fórmula matemática para a convolução discreta bidimensional.

onde $S(x, y)$ é a nova imagem resultante, realçando características como bordas e texturas. Essa operação é a base de arquiteturas modernas de redes neurais convolucionais, amplamente usadas na detecção de doenças em plantas.

Aplicações de processamento de imagem e visão computacional na agricultura têm demonstrado resultados promissores. Sistemas já foram utilizados para contagem de frutos em árvores, monitoramento de estresse hídrico em lavouras e, especialmente, para a identificação de sintomas visuais de doenças em folhas (Ferentinos, 2018).

2.5. Inteligência Artificial e *Machine Learning*

A Inteligência Artificial (IA) investiga métodos para criar agentes capazes de perceber o ambiente, raciocinar e agir de modo a maximizar objectivos (Russell et al., 2010).

No interior da IA, o *machine learning*, (ML) estuda algoritmos que generalizam a partir de dados, melhorando o desempenho numa tarefa definida à medida que recebem experiência (Mitchell, 1997).

2.5.1. Paradigmas de Aprendizagem

Em ML, distinguem-se três paradigmas principais, cada um com papéis diferentes no agro-contexto:

1. **Supervisionada:** segundo Alpaydin (2020), este paradigma permite que o modelo aprenda a mapear entradas para rótulos, associando exemplos de dados a categorias conhecidas. É o caso da classificação de imagens de folhas de mandioca em classes como “saúdável” ou “afectada por CMD”.
2. **Não supervisionada:** conforme Bishop (2006), neste tipo de aprendizagem o algoritmo procura estruturas latentes em dados sem rótulos. Esse processo possibilita a identificação de padrões ocultos, como agrupamentos de sintomas semelhantes em folhas, mesmo sem indicação prévia da doença.
3. **Por reforço:** de acordo com Sutton e Barto (2018), este paradigma baseia-se na aprendizagem por tentativa e erro, em que o agente recebe recompensas ou penalizações de acordo com as suas

acções. Esse modelo pode ser aplicado, por exemplo, em sistemas de recomendação de práticas de manejo adaptativo.



Figura 5: Representação esquemática dos paradigmas de aprendizagem em machine learning: supervisionada, não supervisionada e por reforço

2.5.2. Generalização, *Overfitting* e *Underfitting*

O objectivo fundamental do *machine learning* é generalizar, ou seja, obter bom desempenho não apenas nos dados usados durante o treino, mas também em novos exemplos nunca vistos. Um modelo que generaliza bem é capaz de capturar os padrões reais presentes nos dados, evitando depender de ruídos ou coincidências específicas do conjunto de treino (Hastie et al. 2009).

O *underfitting* acontece quando o modelo é demasiado simples para capturar a estrutura dos dados. Nesse caso, ele não consegue aprender as relações importantes e apresenta erros elevados tanto no treino quanto na validação. As causas mais comuns incluem modelos com poucas camadas ou poucos parâmetros, treino insuficiente (poucas épocas), taxa de aprendizagem inadequada ou pré-processamento limitado. Em contexto agrícola, isto é evidente quando um modelo não consegue distinguir entre doenças com padrões visuais semelhantes, como mancha verde e mancha bacteriana, porque a arquitectura não tem capacidade suficiente para extrair características discriminativas.

Por outro lado, o *overfitting* ocorre quando o modelo é demasiado complexo e acaba por memorizar detalhes irrelevantes, incluindo ruído, iluminação específica ou padrões do fundo das imagens. O modelo

apresenta desempenho excelente nos dados de treino, mas falha ao analisar novas imagens. As causas típicas incluem datasets pequenos ou pouco variados (muito comum na agricultura), muitas épocas de treino, ausência de mecanismos de regularização e modelos muito profundos. No caso de folhas de mandioca, isto acontece quando todas as imagens do dataset são tiradas no mesmo campo, com a mesma iluminação ou o mesmo tipo de fundo. O modelo aprende características do ambiente em vez dos sintomas da doença e, ao receber uma imagem tirada em Boane com outra exposição de luz, erra a classificação.

Para lidar com underfitting, costuma-se aumentar a complexidade do modelo, treinar durante mais épocas, ajustar a taxa de aprendizagem ou melhorar a qualidade das imagens e extração de características. Para reduzir o overfitting, utilizam-se estratégias como regularização (dropout, L2), early stopping, validação estratificada, expansão do dataset e, muito especialmente, técnicas de data augmentation, que simulam novas condições ao aplicar rotações, flips, zooms, variações de brilho e adição de ruído. Essas técnicas ajudam o modelo a aprender os padrões verdadeiros da folha, e não detalhes circunstanciais do ambiente.

Em suma, o underfitting revela falta de capacidade de aprendizagem, enquanto o overfitting indica aprendizagem excessivamente específica. O equilíbrio entre ambos é o que garante boa generalização e é essencial para que um modelo de detecção de doenças em folhas de mandioca funcione correctamente em diferentes campos, câmaras e condições ambientais.

2.5.3. Formulação de Risco Empírico (Aprendizagem Supervisionada)

Num cenário de classificação multiclasse, com pares (x_i, y_i) , aprende-se um modelo f_θ minimizando a perda média (risco empírico) com regularização:

$$\hat{R}(\theta) = \frac{1}{n} \sum_{i=1}^n \ell(f_\theta(x_i), y_i) + \lambda \Omega(\theta) \quad (1)$$

Figura 6: Fórmula da representação do risco empírico regularizado

Logo após definir o risco, especifica-se a saída do modelo como um vector de probabilidades via *softmax* (para K classes):

$$\hat{y}_k = \frac{e^{z_k}}{\sum_{j=1}^K e^{z_j}}, \quad k = 1, \dots, K \quad (2)$$

Figura 7: Fórmula da função Softmax

Em seguida, emprega-se a **entropia cruzada categórica** como função de perda, adequada a multiclasse:

(3)

$$\ell(\hat{y}, y) = - \sum_{k=1}^K \mathbf{1}[y = k] \log(\hat{y}_k)$$

A regularização $\Omega(\theta)$ controla a complexidade do modelo, como penalização L2, para reduzir overfitting.




Figura 9: Fluxo do treino supervisionado

2.5.4. Optimização e *Early Stopping*

A minimização da função de risco definida em (1) é realizada através de métodos de gradiente descendente estocástico (SGD), nos quais os parâmetros do modelo são ajustados de forma iterativa na direcção oposta ao gradiente do erro. Este processo pode ser descrito pela seguinte actualização:

$$\theta_{t+1} = \theta_t - \eta \nabla_{\theta} \hat{R}(\theta_t)$$

Figura 10: Fórmula de actualização de parâmetros na descida do gradiente

Embora o SGD seja amplamente utilizado, apresenta algumas limitações, como oscilações no processo de convergência e sensibilidade à escolha da taxa de aprendizagem. Para superar essas dificuldades, foram desenvolvidos algoritmos de optimização mais avançados. Entre eles destaca-se o Adam (Adaptive Moment Estimation), que combina o conceito de momentum, acumulando informação sobre os gradientes passados — com o ajuste adaptativo da taxa de aprendizagem inspirado no RMSProp. Dessa forma, o Adam consegue actualizar cada parâmetro de forma mais eficiente, acelerando a convergência e tornando o treino mais estável em redes profundas. Uma explicação abrangente encontra-se em Goodfellow et al. (2016).

Além da escolha do algoritmo de optimização, é fundamental adoptar estratégias para prevenir *overfitting*. Uma das mais utilizadas é o *early stopping*, que consiste em interromper o treino quando a perda no

conjunto de validação deixa de melhorar de forma consistente. Este procedimento evita que a rede memorize o ruído dos dados de treino e assegura melhor capacidade de generalização.

2.5.5. Redes Neurais Convolucionais (CNNs)

As Redes Neurais Convolucionais (CNNs) constituem a espinha dorsal da visão computacional moderna. Estas redes capturam padrões locais, como bordas e texturas, através de camadas convolucionais que actuam em pequenas regiões da imagem. As camadas subsequentes processam essas informações de forma hierárquica, permitindo que o modelo aprenda desde padrões simples até estruturas complexas associadas a sintomas de doenças. Um marco fundacional na aplicação deste tipo de rede foi estabelecido por LeCun et al. (1998).

A operação de convolução foi formalizada no ponto 2.4, mas aqui importa sublinhar o seu efeito representacional: a capacidade de construir níveis sucessivos de abstração a partir da imagem de entrada. Essa característica diferencia as CNNs dos métodos clássicos, que dependem de extração manual de características.

No contexto agrícola, as CNNs têm demonstrado desempenho superior em relação a outros algoritmos tradicionais, sobretudo quando as imagens apresentam variações de iluminação, ângulo de captura ou fundo, condições comuns em levantamentos de campo. Ferentinos (2018) evidencia que, aplicadas à classificação de doenças em plantas, as CNNs atingiram resultados de elevado desempenho, reforçando o seu potencial para apoiar diagnósticos agrícolas.

2.5.6. Transfer Learning e Modelos Leves

Quando o dataset disponível é reduzido, torna-se necessária a utilização de transfer learning, isto é, o aproveitamento de uma rede previamente treinada em grandes bases de dados e a sua adaptação ao novo domínio por meio de *fine-tuning*. Entre as arquitecturas mais relevantes destaca-se a ResNet, cuja inovação está no uso de blocos residuais que facilitam o treino de redes profundas, conforme demonstrado por He et al. (2016).

Para aplicações em dispositivos móveis, ganharam destaque arquitecturas mais leves, como a MobileNetV2, que introduz convoluções separáveis em profundidade para reduzir o custo computacional e permitir a execução eficiente em aparelhos com recursos limitados (Howard et al., 2019). Essas estratégias são particularmente relevantes no contexto moçambicano, onde se procura disponibilizar ferramentas de diagnóstico directamente no terreno, muitas vezes em locais sem conectividade constante.




Figura 11: Estrutura simplificada de um bloco residual (ResNet) e de uma convolução separável em profundidade (MobileNetV2)

2.5.7. Regularização e Estratégias de Dados

Além de L2, técnicas como *dropout* e *batch normalization* estabilizam e regularizam o treino. Goodfellow et al. (2016) apresentam ambas de forma didática. No agro-domínio, a estratégia de dados é tão importante quanto a arquitectura:

- **Data augmentation** (rotação, *zoom*, brilho, *flip*) para simular variações de campo;
- **Classes desbalanceadas**: usar *class weights* ou perdas como focal loss para dar mais peso a doenças raras;
- **Domínio local**: sempre que possível, incluir imagens provenientes do contexto moçambicano, de modo a reduzir o dataset shift (diferenças entre os dados usados no treino do modelo e os dados encontrados na aplicação real), aumentando assim a validade externa dos resultados.

2.5.8. Validação e Metodologia Experimental

A avaliação da capacidade de generalização de um modelo de *machine learning* exige a definição de estratégias rigorosas de validação. A prática mais comum consiste em dividir o conjunto de dados em três subconjuntos distintos: treino, validação e teste. O conjunto de treino é utilizado para ajustar os parâmetros do modelo, o conjunto de validação serve para afinar hiperparâmetros e monitorizar o risco de *overfitting*, e o conjunto de teste é reservado para a avaliação final, garantindo uma estimativa imparcial do desempenho.

Quando o número de amostras disponíveis é elevado, esta divisão simples costuma ser suficiente. No entanto, em situações em que os dados são reduzidos, realidade comum em aplicações agrícolas, sobretudo em Moçambique, esta estratégia pode levar a avaliações instáveis, já que pequenas alterações na composição dos subconjuntos podem resultar em grandes variações de desempenho.

Segundo Hastie et al. (2009), uma solução para esse problema é o uso da validação cruzada estratificada. Neste método, o dataset é dividido em k subconjuntos (ou *folds*), preservando a proporção entre as classes. O modelo é treinado $k-1$ vezes e validado no subconjunto restante, repetindo-se o processo

até que todos os subconjuntos tenham sido usados para validação. A média dos resultados fornece uma estimativa mais robusta da capacidade de generalização.

Este procedimento reduz a variância das medidas e assegura que cada exemplo seja utilizado tanto para treino como para validação, sem comprometer a integridade do conjunto de teste. Em contextos agrícolas, esta metodologia é particularmente valiosa, pois garante que o modelo seja exposto à maior diversidade possível de condições ambientais e sintomas, aumentando a sua fiabilidade quando aplicado em campo.

2.5.9. Interpretabilidade e Incerteza

Ferramentas como o Grad-CAM permitem visualizar as regiões da imagem que mais contribuíram para a classificação, indicando onde a rede concentrou a sua atenção e reforçando a confiança do utilizador nos resultados obtidos (Goodfellow et al., 2016).

No que diz respeito à incerteza, a calibração das probabilidades preditas é uma estratégia fundamental para evitar classificações com níveis de confiança artificialmente elevados. Uma das técnicas mais utilizadas nesse contexto é o *temperature scaling*, que ajusta as probabilidades de saída de forma a torná-las mais consistentes com a realidade observada. Esta abordagem é particularmente relevante em aplicações agrícolas, nas quais decisões incorretas podem implicar custos económicos significativos.



Figura 12: Mapa de calor gerado por Grad-CAM

Fonte: Elaborado pelo autor (2025).

2.5.10. Implicações para Agricultura

A adopção de ML em agricultura exige robustez fora do laboratório: variações de aparelhos, iluminação, poeira, danos mecânicos e sintomas confundidores (nutrição *vs* doença). É por isso que transfer learning,

augmentation realista, pesos por classe e validação honesta são pilares do desenho experimental neste domínio. Estudos específicos de doenças da mandioca com CNNs estão reportados por Ramcharan et al. (2017).

2.5.11. Support Vector Machines (SVM)

As Máquinas de Vectores de Suporte (Support Vector Machines – SVM) constituem um método clássico de aprendizagem supervisionada amplamente utilizado em problemas de classificação e regressão. O princípio fundamental do SVM consiste em encontrar um hiperplano que maximize a margem entre diferentes classes no espaço de características, garantindo melhor capacidade de generalização (Alpaydin, 2020).

Em tarefas de classificação de imagens, o SVM não opera directamente sobre os pixels brutos, sendo normalmente aplicado após uma etapa de extracção de características. Estas características podem representar padrões de textura, cor ou bordas previamente calculadas, servindo como entrada para o classificador.

Na agricultura, SVMs foram utilizados em estudos iniciais de detecção de doenças em plantas, apresentando resultados satisfatórios quando os conjuntos de dados são relativamente pequenos e bem estruturados. No entanto, o desempenho tende a degradar-se em cenários com elevada variabilidade visual, como ocorre em imagens captadas em campo, sob diferentes condições de iluminação e fundo. Por esta razão, o SVM é frequentemente utilizado como modelo de referência (baseline) em comparação com arquitecturas profundas, como as redes neurais convolucionais.

2.5.12. K-Nearest Neighbors (KNN)

O algoritmo K-Nearest Neighbors (KNN) é um método de aprendizagem supervisionada baseado em instâncias, no qual a classificação de uma nova amostra é determinada com base na proximidade em relação aos k exemplos mais próximos no conjunto de treino. A decisão final resulta de um processo de votação entre os vizinhos mais próximos, geralmente utilizando uma métrica de distância, como a distância Euclidiana (Alpaydin, 2020).

O KNN destaca-se pela sua simplicidade conceptual e facilidade de implementação, não exigindo uma fase explícita de treino. Contudo, essa simplicidade implica limitações importantes, nomeadamente elevado custo computacional durante a fase de inferência e sensibilidade à escolha do valor de k e à escala das características.

Em aplicações de visão computacional agrícola, o KNN tem sido utilizado principalmente como método comparativo, servindo como referência para avaliar ganhos obtidos por modelos mais sofisticados. Em contextos com elevada complexidade visual, como a identificação de doenças foliares em ambientes reais,

o KNN tende a apresentar desempenho inferior quando comparado a modelos baseados em aprendizagem profunda, devido à sua incapacidade de aprender representações hierárquicas das imagens.

2.6. *Machine Learning* Aplicado à Agricultura

A aplicação de técnicas de *machine learning* (ML) na agricultura tem crescido de forma expressiva nas últimas décadas, impulsionada pela crescente disponibilidade de dados digitais e pela evolução da capacidade computacional. O objectivo é apoiar a tomada de decisão agrícola, aumentando a eficiência produtiva e reduzindo perdas.

Diversos estudos demonstram o potencial do ML em diferentes áreas. Hughes e Salathé (2015) criaram o PlantVillage Dataset, uma das bases de dados mais amplamente utilizadas para a classificação de doenças em plantas. Este recurso tornou-se referência para o desenvolvimento de modelos de diagnóstico automatizado, por fornecer imagens rotuladas de múltiplas culturas agrícolas.

Ferentinos (2018) explorou a aplicação de redes neurais convolucionais (CNNs) em mais de 58 classes de doenças de diferentes culturas e reportou níveis de acurácia superiores a 99% em vários cenários. O autor concluiu que as CNNs superam métodos clássicos como Support Vector Machines (SVM) e Random Forest, sobretudo em tarefas de classificação de imagens.

Outros trabalhos focaram na utilização de ML em dispositivos móveis. Picon et al. (2018) desenvolveram um sistema baseado em CNNs que possibilita a detecção de doenças de plantas em tempo real em *smartphones*, demonstrando que é possível levar estas soluções directamente ao agricultor, sem depender de computadores de elevado desempenho.

No caso específico da mandioca, Ramcharan et al. (2017) demonstraram a eficácia das CNNs na detecção da doença do mosaico da mandioca (CMD) e da doença da estria castanha (CBSD), utilizando imagens capturadas em campo na Tanzânia e em Uganda. Os autores integraram o modelo em uma aplicação móvel, permitindo que agricultores familiares identificassem doenças a partir de fotografias simples tiradas com telemóveis. Este estudo foi posteriormente incorporado ao PlantVillage Nuru, hoje utilizado em vários países africanos.

Em África, outras experiências reforçam esta tendência. Shirima et al. (2022) analisaram o impacto do diagnóstico digital de doenças da mandioca nas Comores e concluíram que a adopção de sistemas móveis contribuiu para reduzir o tempo de identificação de sintomas e melhorar a resposta dos agricultores. No Quênia, iniciativas de diagnóstico digital apoiadas por ML também mostraram que pequenos agricultores podem beneficiar de soluções de baixo custo quando os modelos são optimizados para execução local.

Em Moçambique, embora ainda escasseiem estudos específicos, relatórios do Instituto de Investigação Agrária de Moçambique (IIAM, 2019) apontam a necessidade de integrar abordagens de diagnóstico automatizado para reduzir perdas agrícolas. O PEDSA II (2022–2030) também sublinha a importância

da inovação digital como parte da modernização do sector agrário. Nesse sentido, a adaptação de modelos internacionais de ML ao contexto moçambicano constitui uma oportunidade para promover soluções práticas, acessíveis e sustentáveis, que fortaleçam a segurança alimentar.

Tabela 3: Principais estudos internacionais e africanos sobre aplicação de machine learning na agricultura, com destaque para a detecção de doenças em plantas

Estudo	Cultura/Doença	Modelo	Resultado	Aplicação
Hughes & Salathé (2015)	Várias culturas	PlantVillage Dataset	Criação de base de dados rotulada	Referência internacional
Ferentinos (2018)	58 doenças em plantas	CNNs	Acurácia >99%	Diagnóstico automatizado
Picon (2018)	Várias culturas	CNN em smartphone	Acurácia elevada em tempo real	Uso em dispositivos móveis
Ramcharan (2017)	Mandioca (CMD, CBSD)	CNNs	Acurácia elevada	App móvel → PlantVillage Nuru
Shirima (2022)	Mandioca (Comores)	CNN em app	Redução no tempo de diagnóstico	Suporte directo ao agricultor

Fonte: Autor, adaptado de Hughes & Salathé (2015), Ferentinos (2018), Picon (2018), Ramcharan (2017) e Shirima (2022).

2.7. Estudos Relevantes em África e Moçambique

Embora grande parte da produção científica sobre a aplicação de *machine learning* na agricultura tenha origem em contextos internacionais, África tem registado avanços significativos nesta área, com alguns contributos que se aproximam directamente da realidade moçambicana.

Na Nigéria e no Quénia, o projecto PlantVillage Nuru demonstrou o potencial das redes neurais convolucionais integradas em dispositivos móveis para diagnosticar doenças em culturas de grande importância alimentar. Ramcharan et al. (2019) mostram que o sistema alcançou elevada acurácia na detecção da Doença do Mosaico da Mandioca (CMD) e da Doença da Estria Castanha (CBSD), permitindo que agricultores familiares identificassem sintomas a partir de fotografias simples.

Em Gana, experiências com drones e algoritmos de classificação revelaram que a integração entre imagens aéreas e *machine learning* pode reduzir o tempo de resposta dos técnicos agrícolas e melhorar o acompanhamento das lavouras. Estudos recentes demonstram que a integração de imagens de drones com algoritmos de *machine learning* pode aumentar a precisão na identificação de problemas fitossanitários e otimizar o planeamento agrícola. Um exemplo é o trabalho de Koirala et al. (2019), que revisa

aplicações de visão computacional e aprendizagem profunda para estimativas de rendimento e detecção de frutos. De forma semelhante, Zhou et al. (2017) exploraram o uso de imagens hiperespectrais combinadas com *machine learning* para monitorar o estresse hídrico em lavouras, confirmando o potencial da tecnologia para apoiar a agricultura de precisão.

Nas Comores, Shirima et al. (2022) realizaram uma análise epidemiológica das doenças da mandioca, identificando a elevada incidência de CMD e CBSD, bem como a presença do vector *Bemisia tabaci*. Embora o trabalho não tenha aplicado técnicas de *machine learning*, os resultados reforçam a urgência de desenvolver ferramentas de diagnóstico digital que possam ser utilizadas em pequenos sistemas agrícolas. Em Moçambique, a investigação na área ainda é limitada, mas já existem contribuições relevantes. Siteo (2014) destaca a centralidade da agricultura no desenvolvimento económico e social do país, chamando a atenção para os desafios impostos por pragas e doenças. O Instituto de Investigação Agrária de Moçambique (IIAM, 2019) documenta perdas significativas nas principais culturas alimentares, com destaque para a mandioca. Macondzo (2018), ao estudar as combinações de culturas familiares, reforça a importância da mandioca para a dieta das famílias nas regiões centro e norte do país.

Dados recentes do Instituto Nacional de Estatística (INE, 2023) demonstram que a mandioca continua entre as culturas alimentares de maior crescimento, confirmando a sua relevância estratégica. De forma complementar, o Plano Estratégico para o Desenvolvimento do Sector Agrário (PEDSA II 2022–2030), elaborado pelo Ministério da Agricultura e Desenvolvimento Rural, reconhece a digitalização e o uso de tecnologias inovadoras como pilares fundamentais para a modernização da agricultura e para a construção de maior resiliência no sector.

Apesar destes avanços, continua a verificar-se uma lacuna de estudos que combinem diagnóstico digital e inteligência artificial aplicados ao contexto moçambicano. Esta ausência reforça a pertinência do presente trabalho, que procura adaptar soluções já validadas em outros países às necessidades específicas da agricultura local, contribuindo para a redução de perdas e para o fortalecimento da segurança alimentar.

2.8. Síntese Crítica

A revisão de literatura apresentada neste capítulo permitiu situar o presente estudo no contexto científico e prático da agricultura em Moçambique e em África. Verificou-se que a agricultura continua a ser o pilar da economia nacional e um elemento essencial para a segurança alimentar. Dados recentes do Instituto Nacional de Estatística confirmam a relevância da mandioca como cultura estratégica, tanto pela sua resiliência em condições adversas como pelo seu papel no sustento das famílias rurais.

Foram analisadas as principais doenças que afectam a mandioca, com destaque para a Doença do Mosaico da Mandioca (CMD) e a Doença da Estria Castanha (CBSD), ambas responsáveis por perdas significativas de produção. A revisão demonstrou que os métodos tradicionais de diagnóstico, baseados

em inspeção visual ou em análises laboratoriais, apresentam limitações práticas: dependem de técnicos especializados, são dispendiosos e pouco acessíveis a pequenos agricultores.

Paralelamente, discutiu-se o papel das tecnologias digitais e do processamento de imagem na agricultura, evidenciando como sensores, drones e sistemas móveis já contribuem para a monitorização das culturas. Estudos internacionais e africanos confirmaram o potencial de técnicas de *machine learning*, em especial as redes neurais convolucionais, para a classificação automática de doenças em plantas. Casos como o PlantVillage Nuru, no Quênia e na Nigéria, exemplificam soluções acessíveis que democratizam o diagnóstico no campo.

Apesar de soluções como o PlantVillage Nuru demonstrarem a viabilidade do uso de *deep learning* no contexto africano, diversos estudos recentes mostram que modelos treinados em datasets controlados tendem a apresentar degradação significativa de desempenho quando aplicados em ambientes reais de campo. Este fenómeno, conhecido como *domain shift*, ocorre devido a diferenças nas condições de iluminação, qualidade das imagens, fundos complexos, ruído visual e diversidade agroecológica presentes em cenários reais de produção agrícola.

Em países como Moçambique, onde predominam pequenos agricultores com acesso limitado a dispositivos avançados e conectividade reduzida, estes desafios tornam-se ainda mais evidentes. Além da limitação de dados locais, questões relacionadas com infraestrutura computacional, custo de implementação e confiança dos utilizadores também influenciam a adopção prática de soluções baseadas em inteligência artificial.

Neste contexto, modelos leves como a MobileNetV2 tornam-se particularmente relevantes devido ao seu equilíbrio entre desempenho e eficiência computacional, permitindo execução em dispositivos móveis de baixo custo. Contudo, a literatura recente demonstra que ainda existem limitações relacionadas com robustez, generalização e interpretabilidade dos modelos em ambientes agrícolas africanos. Estudos recentes também apontam o crescimento do uso de arquiteturas mais avançadas, como *Vision Transformers* (ViT), embora modelos leves continuem mais adequados para contextos com limitações computacionais.

Dessa forma, evidencia-se a necessidade de desenvolvimento de datasets locais e estratégias de **adaptação de domínio** (*domain adaptation*), de modo a garantir que os modelos sejam não apenas precisos em laboratório, mas também confiáveis e robustos em condições reais de campo.

Assim, o presente estudo posiciona-se como uma contribuição para a integração de técnicas de inteligência artificial no contexto agrícola moçambicano, enfatizando a necessidade de modelos eficientes, acessíveis e robustos para utilização em ambientes reais de campo. Ao privilegiar abordagens leves e

adaptáveis, o trabalho procura aproximar os avanços recentes em machine learning das limitações práticas enfrentadas pelos pequenos agricultores.

3

Material e Métodos

3.1. Metodologia de pesquisa

A metodologia de pesquisa corresponde ao conjunto de procedimentos e técnicas adoptados para alcançar os objectivos do estudo. De acordo com Gil (2002), a escolha da metodologia deve considerar a natureza do problema investigado, os objectivos definidos e o tipo de resultados que se pretende alcançar. No presente trabalho, a metodologia foi estruturada em quatro dimensões: abordagem, objectivos, natureza e método.

3.1.1. Quanto à Abordagem

Segundo Creswell (2014), as pesquisas podem ser classificadas em qualitativas, quantitativas ou mistas. Este estudo adopta uma abordagem mista, combinando elementos quantitativos e qualitativos:

- **Quantitativa:** por meio da análise estatística do desempenho de diferentes modelos de machine learning (acurácia, precisão, recall, F1-score). A natureza experimental do treino e validação de redes neurais convolucionais enquadra-se claramente nesta dimensão.
- **Qualitativa:** pelo levantamento bibliográfico e análise crítica de estudos anteriores, contextualizando o uso da inteligência artificial na agricultura moçambicana e identificando lacunas existentes.

Esta combinação permite uma compreensão mais ampla do problema, integrando tanto os dados numéricos obtidos nos experimentos quanto a interpretação científica dos resultados no contexto da agricultura em Moçambique.

3.1.2. Quanto aos Objectivos

Conforme a classificação de Lakatos e Marconi (2003), este trabalho é:

- **Exploratório**, porque busca investigar o potencial da inteligência artificial para resolver um problema ainda pouco estudado em Moçambique: a detecção automática de doenças da mandioca. Trabalhos exploratórios permitem gerar hipóteses e apontar caminhos para futuras investigações.

- **Descritivo**, pois descreve a prevalência das doenças, o funcionamento dos algoritmos de *machine learning* e os resultados obtidos nos testes experimentais.

Dessa forma, o estudo não se limita a explorar uma nova área, mas também a descrever, de maneira sistemática, as etapas do processo de desenvolvimento do protótipo.

3.1.3. Quanto à Natureza

Segundo Gil (2002), as pesquisas podem ser teóricas, aplicadas ou metodológicas. Este trabalho classifica-se como aplicado, visto que procura gerar uma solução prática e funcional, direccionada a um problema real: a dificuldade no diagnóstico precoce das doenças da mandioca.

O foco principal está em propor e validar um protótipo computacional baseado em *machine learning*, com potencial de aplicação directa no campo agrícola, em especial junto aos pequenos agricultores moçambicanos.

3.1.4. Quanto ao Método

Em relação ao método, Prodanov e Freitas (2013) destacam que as pesquisas podem adoptar procedimentos como o levantamento, o estudo de caso, o comparativo ou o experimental. No presente estudo, o método adoptado é experimental, uma vez que foram realizados testes controlados de diferentes modelos de *machine learning*, utilizando bases de dados específicas.

Os experimentos seguiram o seguinte fluxo:

1. Selecção do dataset (imagens de folhas de mandioca).
2. Pré-processamento dos dados (normalização, aumento de dados e divisão em conjuntos).
3. Treino dos modelos (CNN e variações com transfer learning).
4. Avaliação dos resultados (acurácia, matriz de confusão, medidas estatísticas).

Essa abordagem permite verificar, de forma sistemática, como diferentes arquitecturas de redes neurais se comportam diante do problema e qual apresenta melhor desempenho para aplicação prática em Moçambique.

3.1.5. Justificação da Metodologia

A escolha desta metodologia deve-se ao carácter inovador do estudo e à necessidade de unir rigor científico com aplicabilidade prática. Conforme defendido por Creswell (2014), a adopção de métodos mistos enriquece a investigação, permitindo não apenas avaliar estatisticamente os resultados, mas também interpretá-los à luz do contexto social, económico e agrícola do país.

Dessa forma, a metodologia escolhida assegura um equilíbrio entre teoria e prática, favorecendo tanto a produção de conhecimento científico quanto o desenvolvimento de soluções concretas para a agricultura moçambicana.

3.2. Materiais

A realização deste trabalho contou com a utilização de diferentes recursos, organizados em três categorias principais: base de dados, ferramentas de software e recursos computacionais. Estes materiais foram seleccionados de forma a assegurar a viabilidade técnica da investigação e a reprodutibilidade dos resultados obtidos.

3.2.1. Base de Dados

A base de dados utilizada neste estudo foi o PlantVillage Dataset, desenvolvido por Hughes & Salathé (2015), um repositório aberto de imagens de folhas de várias culturas agrícolas. Para o caso específico da mandioca (*Manihot esculenta*), foram consideradas cinco classes:

- Folhas saudáveis;
- Mosaico da mandioca (CMD – Cassava Mosaic Disease);
- Listra marrom (CBSD – Cassava Brown Streak Disease);
- Mancha bacteriana;
- Mancha verde.



Figura 13: Imagem de uma folha da mandioca

Fonte: extraída do dataset do Kaggle

Este dataset foi escolhido pela sua ampla utilização em trabalhos de referência internacional e pela acessibilidade pública e gratuita, o que facilita a replicação de estudos semelhantes. A ausência de um dataset local robusto de imagens de mandioca em Moçambique justifica a adopção desta base, ainda que os modelos tenham sido ajustados de forma a contemplar a realidade agroecológica nacional.

3.2.2. Ferramentas de Software

Para o desenvolvimento do protótipo, recorreu-se a um conjunto de ferramentas de software de código aberto e amplamente utilizadas na comunidade científica:

- **Python 3.10** – linguagem de programação principal;
- **TensorFlow** e **Keras** – bibliotecas centrais para a construção, treino e exportação dos modelos de redes neurais convolucionais (CNNs);
- **Scikit-learn** – utilizada para implementação de algoritmos de referência (como SVM e KNN), além de medidas de avaliação;
- **OpenCV** e **Pillow** – para processamento e manipulação de imagens;
- **NumPy** e **Pandas** – para manipulação e análise de dados tabulares;
- **Matplotlib** e **Seaborn** – para visualização gráfica dos resultados experimentais.

Estas ferramentas foram seleccionadas pela sua robustez, documentação extensa e suporte da comunidade científica, permitindo a implementação eficiente dos experimentos.

3.2.3. Recursos Computacionais

O processo de treino e validação dos modelos exigiu recursos computacionais específicos, incluindo:

- **Ambiente em nuvem (Google Colab Pro)** – utilizado para acelerar o processamento através de unidades gráficas (GPU Tesla T4). O Colab foi escolhido pela sua disponibilidade gratuita e pela facilidade de configuração em projectos de pesquisa.
- **Computador portátil local** – um MacBook Air equipado com processador **Apple M2, 8GB de memória RAM** e sistema operativo **macOS Ventura**, utilizado para pré-processamento de dados e testes de integração do protótipo.

A escolha de ambientes híbridos (nuvem + máquina local) possibilitou maior flexibilidade, garantindo tanto a execução eficiente de modelos pesados quanto a reprodutibilidade em condições mais limitadas de hardware.

3.2.4. Ambiente de Implementação

A fase de prototipagem foi conduzida em Jupyter Notebook, devido à sua interatividade no desenvolvimento de modelos e na análise dos resultados. Além disso, foram exploradas bibliotecas de aceleração, como XNNPACK e o GPU delegate, que permitem otimizar o desempenho e a eficiência na execução de inferências em dispositivos móveis Android, possibilitando a utilização do modelo em smartphones com recursos computacionais limitados.




Figura 14: Arquitetura simplificada de uma CNN

3.3. Etapas para o desenvolvimento do modelo de Machine Learning

O desenvolvimento do modelo seguiu uma sequência de etapas técnicas estruturadas para garantir rigor científico e aplicabilidade prática. Essas etapas incluíram a colecta e pré-processamento de dados, a definição da arquitectura de modelos, o processo de treino e validação, a avaliação por medidas padronizadas e a preparação do modelo final para utilização em dispositivos móveis.




Figura 15: Fluxo metodológico da pesquisa

3.3.1. Colecta e Pré-processamento de Dados

A base de dados utilizada neste estudo foi obtida a partir do PlantVillage Dataset, criado por Hughes e Salathé (2015), amplamente empregado em investigações sobre diagnóstico de doenças em plantas. O subconjunto seleccionado corresponde a folhas de mandioca, organizadas em diferentes categorias, incluindo amostras saudáveis e imagens afectadas por doenças como a Doença do Mosaico da Mandioca (CMD) e a Doença da Estria Castanha (CBSD). A escolha desta base justifica-se pela sua acessibilidade pública e pela ampla utilização em estudos de referência no domínio da visão computacional aplicada à agricultura.

Após a colecta, procedeu-se a um processo de limpeza de dados, removendo imagens duplicadas ou corrompidas, de modo a garantir a consistência do conjunto final. Este procedimento assegurou que cada classe fosse representada de forma fidedigna, reduzindo a introdução de ruídos indesejados durante o treino (Goodfellow et al., 2016).

As imagens foram submetidas a normalização e redimensionamento, sendo ajustadas para dimensões de 224×224 pixels. Esse formato é compatível com arquitecturas modernas de redes convolucionais e equilibra qualidade de representação com eficiência computacional. O processo de normalização dos valores de pixel, transformando-os para uma escala entre 0 e 1, contribuiu para acelerar a convergência do treino e reduzir instabilidades (Bishop, 2006).

Para aumentar a robustez do modelo em condições reais de campo, aplicou-se *data augmentation*, incluindo operações de rotação, inversão horizontal, variação de brilho e *zoom*. Estas técnicas procuram simular variações típicas encontradas no terreno, como diferenças de iluminação e ângulos de captura. A importância da *data augmentation* para a melhoria da generalização de redes profundas é amplamente reconhecida em estudos recentes (Shorten & Khoshgoftaar, 2019).

Finalmente, o conjunto foi dividido em 70% para treino, 15% para validação e 15% para teste. Essa proporção é frequentemente adoptada em tarefas de classificação de imagens, pois assegura quantidade suficiente de dados para aprendizagem e, ao mesmo tempo, uma avaliação independente e confiável do desempenho final do modelo (Hastie, Tibshirani & Friedman, 2009).



Figura 16: *Data augmentation* aplicado a uma folha de mandioca

Fonte: Elaborado pelo autor (2025).

3.3.2. Modelagem

A etapa de modelagem consistiu na definição e implementação dos algoritmos de aprendizagem automática responsáveis pela classificação das imagens de folhas de mandioca. O enfoque principal recaiu sobre as Redes Neurais Convolucionais (CNNs), cuja eficácia em tarefas de visão computacional já foi amplamente demonstrada desde os trabalhos pioneiros de LeCun et al. (1998).

Inicialmente, desenvolveu-se uma CNN construída do zero, composta por camadas convolucionais intercaladas com operações de *pooling*, seguidas de camadas densas totalmente conectadas. Esta arquitetura buscou capturar padrões visuais hierárquicos, desde características simples como bordas e texturas até estruturas mais complexas relacionadas a sintomas de doenças nas folhas.

Em paralelo, explorou-se a abordagem de transfer learning, utilizando arquiteturas pré-treinadas como ResNet50 e MobileNetV2. O uso dessas redes justifica-se pelo aproveitamento de representações previamente aprendidas em grandes bases de dados de imagens, o que permite reduzir o tempo de treino e melhorar a performance em cenários com conjuntos de dados relativamente limitados (He et al., 2016). No caso da MobileNetV2, a principal vantagem está na sua leveza e eficiência, características que favorecem a implementação em dispositivos móveis (Howard et al., 2019).

Além disso, foram implementados modelos clássicos de classificação, como Máquinas de Vetores de Suporte (SVM) e K-Vizinhos Mais Próximos (KNN). Estes algoritmos não possuem a mesma capacidade de generalização de uma CNN em contextos de grande variabilidade visual, mas foram incluídos no estudo como baseline, servindo de referência comparativa para demonstrar o ganho obtido com arquiteturas profundas. Segundo Bishop (2006), modelos mais simples podem ser úteis como ponto de partida metodológico, desde que as suas limitações sejam reconhecidas.

A Figura 17 ilustra a arquitetura geral do modelo proposto, evidenciando as principais etapas do fluxo: entrada da imagem, extração de características por convoluções, redução dimensional por pooling, camadas densas para integração da informação e, por fim, a saída probabilística via *softmax*, que fornece a classe prevista para cada folha.




Figura 17: Arquitetura geral do modelo CNN proposto

Fonte: Elaborado pelo autor adaptado de LeCun et al. (1998).

3.3.3. Treino e Validação

O processo de treino do modelo foi conduzido em ambiente Python, com suporte da biblioteca TensorFlow/Keras, escolhida pela sua flexibilidade e ampla adoção em tarefas de visão computacional.

O treino teve como objectivo otimizar os parâmetros da rede convolucional, de forma a minimizar a função de perda e maximizar a capacidade de generalização do modelo para novos dados.

A função de perda adoptada foi a entropia cruzada categórica, apropriada para problemas de classificação multiclasse, em que se pretende atribuir uma probabilidade a cada categoria de saída. Esta função mede a discrepância entre a distribuição prevista pelo modelo e a verdadeira distribuição dos rótulos, orientando o ajuste dos pesos internos durante o processo de aprendizagem (Goodfellow et al., 2016).

Como método de optimização, utilizou-se o Adam, reconhecido pela sua capacidade de combinar as vantagens do gradiente descendente estocástico com ajustes adaptativos de taxa de aprendizagem. Essa escolha buscou garantir estabilidade no treino e rapidez na convergência, mesmo em cenários de elevada variabilidade visual (Kingma & Ba, 2015).

O treino foi conduzido em múltiplas épocas, com lotes de dados (*batch size*) ajustados de forma a equilibrar a velocidade de processamento e a estabilidade dos gradientes. A monitorização do desempenho foi realizada através do conjunto de validação, permitindo acompanhar a evolução da perda e da acurácia em tempo real.

Para mitigar o risco de *overfitting*, adoptou-se a técnica de *early stopping*, interrompendo o treino quando a perda de validação deixava de melhorar após determinado número de épocas consecutivas. Adicionalmente, foram empregadas camadas de *dropout* e regularização L2 em camadas densas, estratégias que reduzem a complexidade do modelo e favorecem a sua capacidade de generalização (Srivastava et al., 2014).

Os resultados parciais do treino foram comparados entre diferentes arquitecturas, incluindo CNN construída do zero, ResNet50 e MobileNetV2, de modo a avaliar o equilíbrio entre desempenho, tempo de treino e viabilidade de implementação prática em dispositivos móveis.

Tabela 4: Tabela comparativa das Arquitecturas CNNs

Arquitectura	Tempo de treino (épocas)	Tamanho do modelo	Desempenho esperado	Aplicabilidade móvel
CNN do zero	Moderado	Pequeno (~5-10 MB)	Bom em datasets simples	Limitada
ResNet50	Alto	Grande (>100 MB)	Muito alto em datasets complexos	Difícil (modelo pesado)
MobileNetV2	Baixo	Leve (~14 MB)	Alto, optimizado para mobile	Alta (modelo optimizado)

3.3.4. Medidas de Avaliação

A avaliação do desempenho do modelo é um elemento essencial para aferir a sua capacidade de generalização e a adequação prática ao diagnóstico de doenças da mandioca. Para este fim, foram utilizadas medidas consagradas em problemas de classificação multiclasse, cada uma oferecendo uma perspectiva complementar sobre a performance do sistema.

A acurácia corresponde à proporção de previsões correctas em relação ao total de amostras avaliadas, sendo uma métrica intuitiva e frequentemente utilizada em estudos iniciais de classificação. A sua formulação é dada por:

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN}$$

Figura 18: Fórmula da acurácia

onde TP representa verdadeiros positivos, TN verdadeiros negativos, FP falsos positivos e FN falsos negativos (Bishop, 2006).

A precisão indica a proporção de exemplos classificados como positivos que de facto pertencem à classe correcta. É especialmente relevante quando o custo de falsos positivos é elevado:

$$\text{Precisão} = \frac{TP}{TP + FP}$$

Figura 19: Fórmula da precisão

Por outro lado, o recall (ou sensibilidade) mede a capacidade do modelo de identificar correctamente todos os casos positivos, minimizando falsos negativos:

$$\text{Recall} = \frac{TP}{TP + FN}$$

Figura 20: Fórmula de recall

Como forma de equilibrar precisão e recall, empregou-se o **F1-score**, definido como a média harmónica entre ambas as medidas:

$$F1 = 2 \cdot \frac{\text{Precisão} \cdot \text{Recall}}{\text{Precisão} + \text{Recall}}$$

Figura 21: Fórmula de F1 Score

Essa métrica é particularmente útil em bases de dados desbalanceadas, pois pondera tanto a capacidade de identificar positivos quanto a fiabilidade das classificações (Powers, 2011).

Além das medidas numéricas, foi utilizada a matriz de confusão, que permite observar o desempenho do classificador em cada classe individualmente. Essa ferramenta visual facilita a identificação de padrões de erro, como a confusão recorrente entre classes de sintomas semelhantes, contribuindo para uma análise mais detalhada da performance do modelo (Fawcett, 2006).

3.3.5. Exportação e Optimização do Modelo

Após o treino e validação, o modelo final foi preparado para uso em dispositivos móveis, visando sua aplicabilidade prática no contexto agrícola. Para isso, o modelo foi convertido para o formato TensorFlow Lite (TFLite), que possibilita a execução em plataformas de recursos limitados, como *smartphones*. A conversão para TFLite reduz a complexidade computacional, mantendo a integridade da estrutura original da rede (TensorFlow, 2021).

Durante o processo de exportação, aplicaram-se técnicas de quantização, que consistem na redução da precisão dos parâmetros do modelo (por exemplo, de 32 bits em ponto flutuante para 8 bits inteiros – INT8). Essa abordagem diminui o tamanho do modelo e melhora a velocidade de inferência, com impacto mínimo na acurácia global (Jacob et al., 2018).

Além disso, foram exploradas optimizações específicas do TFLite, como o uso do XNNPACK e do GPU delegate, que permitem acelerar cálculos matriciais em hardware moderno. Durante o processo de exportação, aplicaram-se técnicas de quantização INT8 e optimização com XNNPACK, conforme observado por Marat Dukhan (2020), que reporta em média ganhos de desempenho de 2,3x em inferência em dispositivos móveis.

Essas adaptações têm relevância especial no contexto moçambicano, onde a conectividade à internet é limitada em muitas zonas rurais e o acesso a dispositivos de alto desempenho nem sempre é garantido. A disponibilização de um modelo optimizado para execução offline e em tempo real em *smartphones* contribui para tornar a solução mais acessível e eficaz para agricultores familiares.

A Figura 22 apresenta um fluxograma ilustrativo do processo de exportação, destacando as etapas de treino do modelo, conversão para TFLite, aplicação de quantização e execução final em dispositivo móvel.




Figura 22: Fluxo de exportação e optimização do modelo para mobile

3.4. Métodos de Implementação

Esta secção descreve os métodos adoptados para a implementação da solução proposta, abrangendo os requisitos do sistema, a modelação da aplicação e as tecnologias utilizadas. Diferentemente de trabalhos que possuem um capítulo específico para o desenvolvimento da solução, optou-se por integrar esses elementos neste ponto, garantindo coerência metodológica entre o desenho experimental e a implementação prática do sistema.

3.4.1. Visão Geral da Solução Proposta

A solução desenvolvida consiste numa aplicação móvel, implementada em Flutter, destinada à classificação automática de doenças em folhas de mandioca a partir de imagens. O sistema integra um modelo de aprendizagem profunda previamente treinado e convertido para TensorFlow Lite, permitindo a execução da inferência directamente no dispositivo móvel, sem necessidade de ligação à internet.

O fluxo de funcionamento da aplicação envolve a captura ou selecção de uma imagem da folha, o pré-processamento da imagem, a classificação automática pelo modelo e a apresentação do resultado ao utilizador, incluindo a classe identificada e o respectivo nível de confiança. As análises realizadas podem ser armazenadas localmente para consulta posterior.

3.4.2. Requisitos Funcionais

Os requisitos funcionais descrevem o que ele deve fazer. É fundamental para definir o escopo e as funcionalidades do sistema.

Tabela 5: Requisitos Funcionais

ID	Nome	Descrição	Prioridade
RF01	Tirar fotografia	Permite ao utilizador com recurso a câmara do dispositivo móvel.	Média

RF02	Carregar fotografia	Permite ao utilizador carregar uma foto existente na galeria de fotos.	Alta
RF03	Efectuar diagnóstico	Permite ao utilizador fazer o diagnóstico da planta com recurso ao <i>upload</i> imagens da planta.	Alta
RF04	Gerar relatório	Permite ao utilizador observar o comportamento dos resultados do diagnóstico por período.	Alta
RF05	Exportar resultado	Permite partilhar os relatórios, e resultados dos diagnósticos.	Média

3.4.3. Requisitos Não Funcionais

Os requisitos não funcionais são requisitos que não estão directamente relacionados com os serviços específicos oferecidos pelo sistema a seus usuários, ou seja, os requisitos não funcionais referem-se a restrições nas funcionalidades ou serviços que o sistema prove.

Tabela 6: Requisitos não funcionais

ID	Nome	Descrição	Prioridade
RNF01	Tempo de resposta	A aplicação precisa processar as solicitações sem enfrentar limitações de conectividade com a internet e deve fornecer respostas em um tempo inferior a 1 minuto.	Média

RNF02	Precisão	O nível de confiança do algoritmo deve ser, no mínimo, de 80%.	Alta
RNF03	Consumo de Recursos Computacionais	Deve utilizar a menor quantidade possível de recursos computacionais.	Média
RNF04	Fácil utilização	O sistema deve ter uma interface fácil de usar e intuitiva.	Média

3.4.4. Modelação e Arquitectura do Sistema

Para descrever a estrutura e o funcionamento da aplicação, foram utilizados diagramas da Linguagem de Modelação Unificada (UML) e um Diagrama Entidade–Relacionamento (ER).

O diagrama entidade–relacionamento representa a estrutura da base de dados local utilizada pela aplicação, assegurando consistência e organização no armazenamento das análises realizadas.




Figura 23: Diagrama Entidade-Relacionamento

O diagrama de sequência ilustra o fluxo temporal das interações durante o processo de análise de uma folha, desde a captura da imagem até à apresentação do diagnóstico ao utilizador.




Figura 24: Diagrama de Sequência

3.4.5. Tecnologias e Ferramentas Utilizadas

A implementação da solução proposta envolveu a utilização de um conjunto de tecnologias modernas e amplamente consolidadas, seleccionadas de acordo com os requisitos funcionais e não funcionais definidos anteriormente, bem como com as limitações de infraestrutura do contexto agrícola moçambicano.

No desenvolvimento de aplicações móveis multiplataforma, diferentes tecnologias podem ser utilizadas, incluindo desenvolvimento nativo, React Native e Flutter. O desenvolvimento nativo oferece elevado desempenho, porém exige bases de código separadas para Android e iOS, aumentando o esforço de manutenção. Já frameworks híbridos como React Native e Flutter permitem reutilização de código e desenvolvimento mais rápido.

Neste trabalho, optou-se pelo Flutter devido ao seu elevado desempenho, capacidade de compilação nativa e facilidade de construção de interfaces modernas e responsivas a partir de uma única base de código. Além disso, o Flutter apresenta boa integração com funcionalidades do dispositivo, como a câmara, tornando-se adequado para aplicações móveis de processamento e análise de imagens. A linguagem Dart foi utilizada como base para a implementação da lógica da aplicação, incluindo a gestão

da interface do utilizador, a interação com a câmara do dispositivo e o controlo do fluxo de análise das imagens.

Para a execução do modelo de classificação no dispositivo móvel, recorreu-se ao TensorFlow Lite, uma versão optimizada do TensorFlow destinada a ambientes com recursos limitados. A utilização do TensorFlow Lite permitiu a realização de inferência local, garantindo que o sistema funcione sem dependência de ligação à internet, factor essencial para a utilização da aplicação em zonas rurais. O modelo treinado em ambiente Python foi convertido para o formato *.tflite*, possibilitando a sua integração directa na aplicação Flutter.

O treino e a validação dos modelos de aprendizagem profunda foram realizados em Python, recorrendo à biblioteca TensorFlow/Keras para a definição das arquitecturas, ajuste dos hiperparâmetros e avaliação do desempenho. Bibliotecas auxiliares, como NumPy e OpenCV, foram utilizadas para manipulação e pré-processamento das imagens, enquanto Matplotlib auxiliou na visualização das métricas e curvas de treino.

Para o armazenamento local das informações resultantes das análises, foi utilizada uma base de dados SQLite, integrada na aplicação móvel. Essa abordagem permitiu guardar o histórico de análises de forma simples e eficiente, sem necessidade de um servidor remoto. O acesso à base de dados é gerido internamente pela aplicação, assegurando persistência e organização dos dados.

O controlo de versões e a gestão do código-fonte foram realizados através da plataforma GitHub, facilitando o acompanhamento das alterações, a organização do projecto e a reprodutibilidade do desenvolvimento. Adicionalmente, ambientes como Jupyter Notebook e Google Colab foram utilizados durante a fase experimental para documentação do código e execução dos treinos em ambiente com suporte a GPU.

Em conjunto, as tecnologias e ferramentas seleccionadas permitiram o desenvolvimento de uma solução eficiente, portátil e adaptada à realidade local, assegurando coerência entre a proposta metodológica da monografia e a implementação prática do sistema.

Experimentos e Resultados

4.1. Configuração dos Experimentos

A fase experimental teve como finalidade avaliar o desempenho e a robustez dos modelos de aprendizagem profunda aplicados à identificação automática de doenças em folhas de mandioca. O objectivo central foi medir a capacidade de generalização das redes convolucionais testadas, tanto as desenvolvidas do zero quanto as que utilizaram *transfer learning*, e validar a viabilidade prática da aplicação em ambiente real, considerando as limitações computacionais típicas de dispositivos móveis e o contexto agrícola moçambicano.

4.1.1. Ambiente Computacional

Os experimentos foram conduzidos em dois ambientes complementares:

- **Ambiente local:** um *MacBook Air* com chip Apple M2, CPU de 8 núcleos e 8 GB de RAM, usado para tarefas de pré-processamento, preparação de dados e testes preliminares.
- **Ambiente remoto:** Google Colab Pro, que oferece suporte a GPU Tesla T4 e CUDA/cuDNN, utilizado para o treino das redes mais complexas (ResNet50 e MobileNetV2), cujos tempos de processamento local seriam excessivos.

O código-fonte foi desenvolvido em Python 3.10, com as seguintes bibliotecas principais:

- **TensorFlow/Keras**, para construção, treino e exportação dos modelos;
- **OpenCV**, para manipulação e visualização das imagens;
- **NumPy e Pandas**, para organização e análise dos dados;
- **Matplotlib e Seaborn**, para geração de gráficos e visualização dos resultados.

Todas as experiências foram documentadas em Jupyter Notebooks, garantindo reprodutibilidade e rastreabilidade das configurações, hiperparâmetros e resultados.

4.1.2. Configuração dos Dados

A base de dados utilizada foi o PlantVillage Dataset (Hughes & Salathé, 2015), seleccionando especificamente o subconjunto referente à cultura da mandioca (*Manihot esculenta Crantz*). Este subconjunto inclui cinco classes de imagens rotuladas:

- i. **Folha saudável**

- ii. **Doença do Mosaico da Mandioca (CMD)**
- iii. **Doença da Estria Castanha (CBSD)**
- iv. **Mancha bacteriana**
- v. **Mancha verde**

O conjunto foi submetido a uma limpeza inicial, removendo imagens duplicadas, corrompidas e aquelas com enquadramento inadequado (por exemplo, folhas parcialmente visíveis ou com sombras excessivas). Após esta triagem, cada imagem foi redimensionada para 224×224 pixels e normalizada para valores entre 0 e 1, seguindo práticas recomendadas em visão computacional (Bishop, 2006).

A divisão dos dados seguiu a proporção de 70 % para treino, 15 % para validação e 15 % para teste, assegurando a independência entre conjuntos e minimizando o risco de *data leakage*. A escolha desta divisão foi baseada em boas práticas consolidadas em tarefas de classificação de imagens (Hastie et al., 2009).

Para aumentar a diversidade do conjunto de treino, aplicou-se a técnica de data augmentation, incluindo transformações geométricas e fotométricas como:

- **Rotação aleatória** de até 30° ;
- **Inversão horizontal e vertical**;
- **Zoom** entre 80 % e 120 %;
- **Variação de brilho e contraste**;
- **Translação** em pequenas escalas (± 10 px).

Essas variações permitiram que o modelo aprendesse a reconhecer sintomas sob diferentes condições de iluminação e ângulos de captura, simulando cenários reais de campo, uma abordagem especialmente importante em Moçambique, onde as imagens recolhidas podem variar em qualidade e dispositivo de origem.

4.1.3. Configuração dos Modelos e Parâmetros

Três arquiteturas principais foram avaliadas:

- **CNN desenvolvida do zero**, com três blocos convolucionais seguidos de camadas densas e activação *softmax* na saída.
- **MobileNetV2**, utilizada com *transfer learning*, pré-treinada no ImageNet, ajustada (*fine-tuning*) para as cinco classes da mandioca.
- **ResNet50**, também pré-treinada no ImageNet, empregada como referência de alta capacidade de extração de características.

Os hiperparâmetros foram definidos empiricamente, conforme o desempenho observado nos conjuntos de validação:

- **Batch size:** 32
- **Número de épocas:** 20
- **Função de perda:** *categorical crossentropy*
- **Optimizador:** *Adam*, com taxa de aprendizagem inicial de 0.001
- **Critério de paragem antecipada:** *EarlyStopping* com paciência de 5 épocas
- **Regularização:** *dropout* (0.4) nas camadas densas

Durante o treino, foram registadas as curvas de perda e acurácia tanto para o conjunto de treino quanto para o de validação, permitindo monitorar sinais de *overfitting* e ajustar o grau de *fine-tuning* nas redes pré-treinadas.

4.1.4. Fluxo Experimental

A Figura 18 ilustra o fluxo geral do processo experimental, composto por seis etapas principais:

1. **Carregamento e preparação das imagens;**
2. **Pré-processamento e *augmentation*;**
3. **Definição do modelo** (CNN, MobileNetV2 ou ResNet50);
4. **Treino e validação cruzada;**
5. **Avaliação final com o conjunto de teste;**
6. **Exportação para TensorFlow Lite** e optimização para *mobile inference*.

Essa configuração foi projectada para equilibrar desempenho, interpretabilidade e aplicabilidade prática, garantindo que o modelo resultante possa ser executado de forma eficiente em dispositivos móveis sem depender de conectividade constante.

4.2. Treino dos Modelos

O processo de treino teve como principal objectivo ajustar os parâmetros das arquitecturas seleccionadas, CNN desenvolvida do zero, MobileNetV2 e ResNet50, de forma a maximizar o desempenho na classificação multiclasse de folhas de mandioca.

Em todas as variantes, adoptou-se a entropia cruzada categórica como função de perda, por ser amplamente utilizada em problemas de classificação com múltiplas categorias, e o optimizador Adam, reconhecido pela sua capacidade de combinar rapidez de convergência e estabilidade numérica na actualização dos pesos (Goodfellow et al., 2016).

Essas escolhas asseguraram um equilíbrio entre eficiência computacional e precisão do processo de aprendizagem, permitindo que os modelos convergissem de forma controlada, mesmo sob variações de iluminação e textura nas imagens.

4.2.1. Ambiente Computacional

O treino foi conduzido para otimizar a capacidade de generalização dos modelos em cenário multiclasse, contemplando cinco categorias de folhas de mandioca: saudáveis, CMD, CBD, mancha bacteriana e mancha verde. A implementação foi realizada em Python, com o framework TensorFlow/Keras, adotando entropia cruzada categórica como função de perda e o otimizador Adam. O Adam foi escolhido por combinar a eficiência do gradiente estocástico com a adaptação dinâmica das taxas de aprendizagem, o que melhora a estabilidade durante o treino de redes profundas (Kingma & Ba, 2015).

Para garantir a reprodutibilidade dos experimentos, foram fixadas *seeds* nos geradores aleatórios do Python, NumPy e TensorFlow. Também se ativou o embaralhamento (*shuffle*) dos dados a cada época, assegurando que as amostras de treino fossem distribuídas de forma aleatória e equilibrada entre as classes. Essa abordagem reduziu o risco de viés e tornou os resultados mais consistentes (Goodfellow et al., 2016).

Em casos de desbalanceamento entre classes, foram aplicados pesos proporcionais na função de perda, atribuindo maior importância às categorias com menos exemplos. Essa estratégia mostrou-se mais eficiente que a simples repetição de amostras minoritárias, evitando o *overfitting* causado pela duplicação de imagens (Bishop, 2006).

A taxa de aprendizagem inicial foi definida em **0,001**, sendo ajustada automaticamente através do método *ReduceLROnPlateau*. Sempre que a perda de validação se mantinha estável por duas épocas consecutivas, a taxa era reduzida em 10%, permitindo um refinamento mais suave dos pesos. Esse mecanismo de ajuste dinâmico tornou o processo de treino mais estável e facilitou a convergência para mínimos globais (Hastie et al., 2009).

A regularização foi implementada por meio de camadas de *dropout* com probabilidade de 0,4 e penalização L2 nos pesos das camadas densas. Além disso, utilizou-se o método de paragem antecipada (*early stopping*), com paciência de cinco épocas, interrompendo o treino quando a perda de validação deixava de diminuir. Essa combinação de técnicas ajudou a equilibrar desempenho e capacidade de generalização, evitando que o modelo memorizasse ruído do conjunto de treino (Shorten & Khoshgoftaar, 2019).

Os modelos foram treinados por até 20 épocas, com *batch size* de 32, e avaliados continuamente nas medidas de acurácia e perda. Para avaliar a consistência dos resultados, cada modelo foi treinado três vezes com inicializações diferentes, reportando-se a média e o desvio-padrão obtidos.

Por fim, realizou-se uma análise comparativa entre configurações de treino, testando variações como o uso ou não de *data augmentation*, a activação da redução automática da taxa de aprendizagem e a aplicação

de pesos por classe. Esses testes experimentais permitiram identificar quais parâmetros contribuíram de forma mais relevante para o ganho de desempenho final.

4.2.2. CNN desenvolvida do zero

A primeira arquitectura implementada foi uma Rede Neural Convolutacional (CNN) desenvolvida do zero, projectada especificamente para o conjunto de dados da mandioca. O objectivo foi compreender o comportamento de um modelo criado do início, sem dependência de pesos pré-treinados, e estabelecer uma linha de base de desempenho.

A rede foi estruturada em três blocos convolucionais sequenciais, compostos por filtros de 32, 64 e 128 *kernels*, cada um seguido por uma camada de *pooling* e activação ReLU. Após a etapa convolutacional, adicionou-se uma camada *flatten*, duas camadas densas e uma camada de saída com função *softmax*, configurada para as cinco classes de folhas. Essa configuração permitiu que o modelo extraísse gradualmente padrões visuais de baixa e alta complexidade, como bordas, manchas e texturas.

Durante a fase de treino, observou-se que a rede convergia de forma estável após cerca de 12 a 15 épocas. Essa estabilidade deve-se à aplicação de normalização dos dados e *data augmentation*, que reduziram o risco de *overfitting*. Segundo Bishop (2006), a diversificação das amostras de treino contribui para que o modelo aprenda representações mais generalizáveis.

Para controlar a complexidade, foi utilizada regularização L2 nos pesos e camadas de *dropout* com probabilidade de 0,4. Essas técnicas reduziram a diferença entre a perda de treino e validação, permitindo uma melhor adaptação do modelo às variações naturais das imagens. Goodfellow et al. (2016) reforçam que a regularização é essencial em redes treinadas a partir do zero, uma vez que estas tendem a memorizar ruído quando o conjunto de dados é limitado.

A arquitectura foi implementada utilizando a API sequencial do Keras, o que facilitou o ajuste dos hiperparâmetros e a monitorização das medidas de desempenho em tempo real. Para avaliação, empregaram-se as medidas de acurácia, precisão, *recall* e F1-score, descritas no Capítulo 3.

De modo geral, a CNN desenvolvida do zero apresentou desempenho satisfatório, atingindo resultados estáveis e consistentes entre as repetições de treino. No entanto, verificou-se que, apesar da boa acurácia em treino, o modelo exigia mais épocas para alcançar níveis de desempenho próximos aos obtidos pelas redes pré-treinadas. Essa diferença é esperada, visto que os modelos treinados do zero não se beneficiam de representações visuais previamente aprendidas, dependendo totalmente da informação contida no conjunto local (Hastie et al., 2009).

4.2.3. MobileNetV2 (*Transfer Learning*)

A segunda arquitetura implementada foi a MobileNetV2, baseada na técnica de *transfer learning*, isto é, o reaproveitamento de conhecimentos previamente aprendidos por um modelo treinado em um grande conjunto de dados genéricos, no caso, o ImageNet, que contém mais de 14 milhões de imagens distribuídas em mil classes. Essa abordagem permite reduzir o tempo de treino e melhorar a performance, especialmente quando o conjunto de dados local é de menor dimensão (Howard et al., 2019).

A escolha da MobileNetV2 deve-se ao seu equilíbrio entre eficiência computacional e desempenho, tornando-a particularmente adequada para execução em dispositivos móveis. A arquitetura utiliza convoluções separáveis em profundidade (*depthwise separable convolutions*) e blocos invertidos residuais (*inverted residuals*), que reduzem drasticamente o número de parâmetros sem comprometer a capacidade de extração de características relevantes. Essa combinação torna o modelo leve e rápido, características fundamentais para aplicações de diagnóstico agrícola em campo.

Durante a adaptação do modelo, todas as camadas convolucionais da MobileNetV2 foram inicialmente congeladas, preservando os pesos pré-treinados no ImageNet. Em seguida, adicionaram-se camadas densas personalizadas para o problema em estudo, culminando numa camada de saída *softmax* com cinco neurónios correspondentes às classes de folhas. Após a estabilização do treino inicial, procedeu-se ao *fine-tuning* parcial, descongelando gradualmente cerca de 20 % das camadas superiores para que o modelo pudesse ajustar as suas representações às particularidades visuais das folhas de mandioca.

Essa estratégia combinada, *freezing* seguido de *fine-tuning* controlado, permitiu reduzir o risco de *overfitting* e melhorar a capacidade de generalização. Segundo Goodfellow et al. (2016), o *transfer learning* é particularmente eficaz quando as características extraídas nas camadas iniciais são universais, como bordas, texturas e padrões de cor, e apenas as camadas superiores precisam ser ajustadas ao novo domínio.

O modelo foi treinado com batch size 32, taxa de aprendizagem inicial de 1×10^{-4} e *early stopping* com paciência de cinco épocas. Durante os experimentos, a MobileNetV2 apresentou rápida convergência, alcançando valores elevados de acurácia já nas primeiras 10 épocas, e mantendo uma diferença reduzida entre perda de treino e validação. Essa consistência é indicativa de uma boa generalização.

Em termos de desempenho, observou-se que a MobileNetV2 obteve acurácia superior à CNN desenvolvida do zero, com tempo de treino significativamente menor e tamanho final do modelo inferior a 15 MB. Esses resultados reforçam o potencial do *transfer learning* para aplicações práticas em contextos com restrições de recursos, como o agrícola moçambicano, onde a utilização de modelos leves em dispositivos móveis é uma condição essencial para a adoção em campo.

4.2.4. ResNet50 (*Transfer Learning*)

A terceira arquitectura avaliada foi a ResNet50, uma das redes convolucionais mais influentes no campo do *deep learning* devido à introdução dos blocos residuais (*residual blocks*), que permitem o treino de redes muito profundas sem sofrer com o problema da degradação de gradientes. Essa inovação possibilita que a rede aprenda representações mais complexas sem perda de desempenho, mesmo com dezenas de camadas empilhadas (He et al., 2016).

A implementação seguiu o mesmo princípio de *transfer learning* aplicado à MobileNetV2, utilizando pesos pré-treinados no ImageNet. As camadas iniciais da rede foram congeladas, preservando os filtros responsáveis por captar padrões genéricos, como bordas e texturas, enquanto as camadas finais foram ajustadas ao domínio da mandioca. Sobre a base convolucional, adicionaram-se uma camada *GlobalAveragePooling2D*, uma camada densa intermediária com activação ReLU e uma camada de saída *softmax* com cinco neurónios, correspondentes às classes do problema.

O treino foi conduzido em duas fases: na primeira, apenas as novas camadas densas foram treinadas, mantendo a base convolucional congelada; na segunda, aplicou-se *fine-tuning* parcial, descongelando aproximadamente 30 % das últimas camadas para refinar a aprendizagem das características específicas das folhas. Essa abordagem incremental permitiu reduzir o risco de *overfitting* e acelerar a convergência.

Durante o treino, a ResNet50 demonstrou alta estabilidade e capacidade de generalização, alcançando níveis elevados de acurácia no conjunto de validação. No entanto, observou-se que o modelo exigiu maior tempo de processamento e memória computacional em comparação com a MobileNetV2, o que é esperado em arquitecturas mais profundas e complexas. Apesar disso, o desempenho final foi ligeiramente superior, especialmente nas classes com sintomas visuais mais sutis, como a diferenciação entre *mancha verde* e *mancha bacteriana*.

Os resultados obtidos evidenciam que a ResNet50 oferece maior poder discriminativo, embora a um custo computacional superior. Isso reforça a importância de equilibrar desempenho e viabilidade de implementação. Em contextos com recursos de hardware limitados, como em aplicações agrícolas móveis, o modelo mais leve (MobileNetV2) apresenta vantagem prática; contudo, em ambiente de laboratório ou servidor, a ResNet50 pode ser preferida pelo seu desempenho marginalmente superior.

Essas observações estão em consonância com a literatura recente, que destaca a ResNet como uma das arquitecturas mais robustas para tarefas de classificação de imagens em domínios agrícolas e biológicos, graças à sua capacidade de extrair características profundas e hierarquicamente ricas (Ferentinos, 2018).

4.2.5. Controle de *Overfitting* e Reprodutibilidade

Durante os experimentos, foi dada especial atenção à mitigação do *overfitting*, um fenómeno comum em redes neurais quando o modelo memoriza padrões específicos do conjunto de treino e perde a capacidade de generalizar para novos dados. Esse problema é particularmente crítico em bases de imagens agrícolas, onde as variações de luz, ângulo e textura podem induzir o modelo a aprender ruído em vez de características representativas (Bishop, 2006).

Para minimizar esse efeito, foram implementadas múltiplas estratégias de regularização. A primeira consistiu na aplicação de camadas de *dropout*, configuradas com probabilidade de 0,4 nas camadas densas finais. Essa técnica força a rede a esquecer aleatoriamente parte das conexões durante o treino, o que reduz a co-dependência entre neurónios e melhora a generalização. Em paralelo, aplicou-se penalização L2 nos pesos treináveis, que impõe um custo adicional a valores excessivamente grandes, contribuindo para redes mais estáveis e menos propensas ao sobreajuste (Goodfellow et al., 2016).

O uso de *data augmentation* também desempenhou papel essencial no controlo do *overfitting*. Ao introduzir variações artificiais nas imagens originais, como rotação, inversão e alteração de brilho, o modelo foi exposto a uma gama mais ampla de exemplos, aprendendo a identificar as doenças independentemente das condições de captura. Essa estratégia mostrou-se eficaz, reduzindo significativamente a diferença entre as perdas de treino e validação ao longo das épocas (Shorten & Khoshgoftaar, 2019).

Outra medida adoptada foi o *early stopping*, que interrompe automaticamente o treino quando a perda de validação deixa de melhorar após um número predefinido de épocas consecutivas. Esse mecanismo evitou que o modelo continuasse a ajustar-se ao ruído do conjunto de treino, garantindo uma selecção mais rigorosa do ponto óptimo de generalização.

Para assegurar a reprodutibilidade dos resultados, foram definidos valores fixos de *seed* em todas as bibliotecas envolvidas (Python, NumPy e TensorFlow), garantindo que os dados fossem embaralhados e processados de forma consistente entre diferentes execuções. Adicionalmente, os scripts e notebooks foram documentados com versões exactas de cada dependência, o que permite replicar o ambiente experimental e verificar a consistência dos resultados obtidos.

Essas práticas conjuntas, regularização, *augmentation*, *early stopping* e documentação sistemática, contribuíram para resultados mais estáveis, tornando o modelo proposto não apenas mais preciso, mas também mais confiável e cientificamente verificável.

4.2.6. Saídas Esperadas e Análise dos Treinos

A etapa de treino produziu uma série de indicadores quantitativos e visuais que permitiram avaliar o comportamento das diferentes arquitecturas testadas ao longo do processo de aprendizagem. As saídas

principais consistiram em curvas de perda e acurácia, tabelas comparativas de desempenho e registros de tempo de execução, os quais serviram de base para as análises descritas nas secções seguintes.

As curvas de perda e acurácia, registadas para cada época, constituíram o principal instrumento de diagnóstico da estabilidade do treino. Em modelos bem generalizados, as curvas de treino e validação tendem a convergir para valores próximos, sem grandes oscilações ou divergências após múltiplas épocas. Quando essa diferença se torna acentuada, é um sinal de *overfitting* ou *underfitting*. Ao longo dos experimentos, observou-se que tanto a MobileNetV2 quanto a ResNet50 apresentaram curvas suavizadas e estáveis, enquanto a CNN desenvolvida do zero exibiu flutuações mais acentuadas, exigindo mais épocas para atingir convergência satisfatória.

Além das curvas de treino, foram analisadas medidas médias de desempenho, acurácia, precisão, *recall* e F1-score, calculadas sobre o conjunto de validação em cada execução. Os resultados foram expressos como média e desvio-padrão de três execuções independentes, o que permitiu avaliar a consistência dos modelos. Essa abordagem estatística é recomendada para reduzir a influência de inicializações aleatórias e garantir maior fiabilidade nas comparações.

As informações obtidas também possibilitaram medir a eficiência computacional dos modelos. A MobileNetV2 apresentou o menor tempo de treino por época e menor utilização de memória, confirmando a sua adequação a dispositivos móveis. A ResNet50, por sua vez, demandou maior tempo de execução, mas compensou com uma ligeira vantagem em acurácia final. Por outro lado, a CNN do zero posicionou-se como uma alternativa intermediária, simples de treinar e interpretar, mas menos eficiente em termos de generalização.

Esses resultados corroboram estudos anteriores que demonstram a relação entre profundidade da arquitectura e poder de generalização, desde que acompanhada de mecanismos adequados de regularização e *fine-tuning* (Hastie et al., 2009). Assim, cada modelo testado desempenhou um papel específico: a CNN serviu como referência de base; a MobileNetV2 demonstrou a aplicabilidade prática; e a ResNet50 representou o limite de desempenho em cenários com maior capacidade computacional.

Os dados e gráficos gerados nesta etapa formam a base para as análises comparativas apresentadas no ponto seguinte, permitindo uma discussão mais detalhada sobre o impacto de cada arquitectura e a robustez do modelo final proposto.

4.3. Resultados da Modelação e Avaliação

A avaliação dos modelos teve como finalidade medir a sua capacidade de generalização e precisão na classificação das cinco classes de folhas de mandioca. Nesta etapa, foram utilizados exclusivamente os

dados do conjunto de teste, que não haviam sido apresentados durante o treino ou validação, garantindo assim uma estimativa imparcial do desempenho real dos modelos.

4.3.1. Resultados da Modelação

Durante a fase de modelação, os três modelos foram treinados utilizando o conjunto de treino e avaliados continuamente no conjunto de validação, permitindo acompanhar o processo de aprendizagem ao longo das épocas. As curvas de accuracy e loss demonstraram convergência progressiva dos modelos, com diferenças significativas entre as arquitecturas utilizadas.

A CNN desenvolvida do zero apresentou convergência mais lenta e maior oscilação entre treino e validação, indicando maior sensibilidade à quantidade limitada de dados. Em contraste, os modelos baseados em transfer learning, MobileNetV2 e ResNet50, apresentaram aprendizagem mais estável e rápida, beneficiando-se dos pesos pré-treinados obtidos a partir do ImageNet.

Observou-se ainda que a MobileNetV2 alcançou um equilíbrio favorável entre estabilidade de treino, custo computacional e desempenho global, enquanto a ResNet50 apresentou maior capacidade de extracção de características complexas, embora com custo computacional significativamente superior.




Figura 25: Curvas de acurácia e loss durante o treino e validação dos modelos: (a,d) CNN (do zero), (b,e) MobileNetV2, (c,f) ResNet50

4.3.2. Medidas de Desempenho

A avaliação dos modelos propostos baseou-se em medidas quantitativas padronizadas que permitem medir de forma objectiva a qualidade da classificação realizada. Estas medidas, acurácia, precisão, recall e F1-score, são amplamente empregadas em problemas de classificação multiclasse, especialmente em tarefas de reconhecimento de padrões em imagens.

A acurácia (Acc) expressa a proporção de classificações correctas em relação ao total de amostras avaliadas. Essa métrica é intuitiva e fornece uma visão geral do desempenho do modelo.

A precisão (P) mede a exactidão das previsões positivas, isto é, o quanto das amostras classificadas como pertencentes a uma determinada classe realmente pertencem a ela.

Por sua vez, o recall (R), também conhecido como sensibilidade, avalia a capacidade do modelo de identificar correctamente todos os elementos positivos. Esta métrica é particularmente relevante em contextos onde é importante evitar omissões, como na detecção de doenças agrícolas, em que um falso negativo pode significar uma planta doente não identificada.

A combinação equilibrada entre precisão e recall é representada pelo F1-score, que corresponde à média harmónica das duas medidas. O F1-score é especialmente útil quando há algum grau de desbalanceamento entre classes, pois oferece uma visão mais justa do desempenho global do modelo.

Além das medidas individuais, foram também utilizadas medidas de média ponderada (*weighted average*), nas quais o contributo de cada classe é ponderado pela sua representatividade no conjunto de dados. Essa abordagem evita que classes com mais amostras dominem o cálculo das médias, proporcionando uma avaliação mais equilibrada do desempenho global (Bishop, 2006).

De modo complementar, foram analisadas as matrizes de confusão para cada modelo, que permitem visualizar a distribuição das previsões correctas e incorrectas entre as classes. Essa ferramenta fornece uma compreensão mais detalhada sobre quais categorias apresentam maior taxa de erro, auxiliando na interpretação qualitativa dos resultados.

As medidas e representações aqui descritas formam o alicerce da análise apresentada nas secções seguintes, permitindo comparar objectivamente a eficácia das três arquitecturas estudadas, CNN, MobileNetV2 e ResNet50, no reconhecimento de doenças em folhas de mandioca.

4.3.3. Desempenho Comparativo entre os Modelos

Após o processo de treino, os modelos foram avaliados no conjunto de teste independente, utilizando as medidas descritas na Secção 4.3.1. A Tabela 5 sintetiza os resultados obtidos para cada arquitectura, CNN

desenvolvida do zero, MobileNetV2 e ResNet50, apresentando os valores médios de acurácia, precisão, *recall* e F1-score, calculados a partir de três execuções consecutivas.

Tabela 7: Desempenho comparativo das arquiteturas testadas.

Modelo	Acurácia (%)	Precisão (%)	Recall (%)	F1-score (%)	Tempo médio por época (s)	Tamanho do modelo (MB)	Tempo médio de inferência (ms/imagem)
CNN (do zero)	89.3	88.6	88.9	88.7	42	9.8	95
MobileNet V2	93.8	93.2	93.5	93.4	27	13.9	28
ResNet50	94.6	94.1	94.4	94.2	79	103	124

Fonte: Elaborado pelo autor (2025).

A análise dos resultados evidencia que todas as arquiteturas alcançaram bom desempenho global, com acurácias superiores a 88%, reflectindo a eficácia dos métodos de pré-processamento e treino adoptados. Contudo, observa-se que os modelos baseados em *transfer learning*, MobileNetV2 e ResNet50, apresentaram desempenho consistentemente superior à CNN construída do zero.

A MobileNetV2 destacou-se pelo melhor equilíbrio entre precisão e eficiência computacional. Com acurácia média de 93.8%, ela superou a CNN tradicional em cerca de 5 pontos percentuais, mantendo um tempo de treino reduzido e um tamanho de modelo inferior a 15 MB. Essa combinação de desempenho e leveza torna-a particularmente adequada para implementação em dispositivos móveis, um requisito essencial para o contexto agrícola moçambicano, onde o acesso a infraestrutura computacional de alto desempenho é limitado.

A ResNet50, por sua vez, apresentou a acurácia mais alta (94.6%), confirmando o seu poder de generalização e capacidade de extrair características mais complexas. No entanto, o custo computacional é significativamente superior, tanto em tempo de treino quanto em espaço de armazenamento, o que limita a sua utilização fora de ambientes laboratoriais. Em contrapartida, a CNN desenvolvida do zero demonstrou desempenho satisfatório, mas com convergência mais lenta e maior variação entre as execuções, o que é esperado em redes de menor profundidade e sem pesos pré-treinados.

Os resultados observados são coerentes com os relatados por Ferentinos (2018), que verificou desempenho acima de 95 % em redes convolucionais aplicadas à identificação de doenças em plantas.

De modo semelhante, Ramcharan et al. (2017) também obtiveram resultados próximos de 93% na detecção de doenças da mandioca utilizando *deep learning* e *transfer learning*, o que reforça a validade dos resultados alcançados neste trabalho.

Em síntese, os resultados comparativos demonstram que o uso de arquitecturas pré-treinadas e optimizadas é fundamental para obter um desempenho robusto em tarefas de diagnóstico agrícola. Assim, a MobileNetV2 foi seleccionada como modelo final para implementação no protótipo, por oferecer o melhor equilíbrio entre precisão, velocidade e viabilidade prática.

4.3.4. Análise Detalhada por Classe

Para uma avaliação mais minuciosa do desempenho do modelo, analisou-se a matriz de confusão resultante da melhor arquitectura, a MobileNetV2, que foi seleccionada como modelo final devido ao seu equilíbrio entre precisão e eficiência. A matriz de confusão permite observar a distribuição das classificações correctas e incorrectas em cada categoria, oferecendo uma visão mais granular do comportamento do modelo.

A Figura 26 ilustra a matriz de confusão obtida após a validação final do modelo no conjunto de teste.




Figura 26: Matriz de confusão obtida pela MobileNetV2

Fonte: Elaborado pelo autor (2025).

4.3.5. Interpretação dos Resultados

Com base na Figura 25, verifica-se que o modelo apresentou elevada precisão na identificação das classes saudável, CMD e CBSD, alcançando taxas de acerto superiores a 95 %. Essas três categorias apresentaram padrões visuais mais distintos entre si, o que facilitou a separação durante o processo de classificação.

A classe saudável foi a mais facilmente reconhecida pelo modelo, evidenciando o bom desempenho da rede em distinguir folhas sem sintomas de doenças. Isso demonstra que o modelo aprendeu a identificar características visuais consistentes de coloração e textura associadas a plantas sãs.

As classes CMD (Doença do Mosaico da Mandioca) e CBSD (Doença da Estria Castanha) também obtiveram desempenho notável, com baixos índices de confusão entre si. Essa precisão elevada deve-se

ao facto de essas doenças apresentarem padrões de sintomas bem definidos, como manchas cloróticas e nervuras amareladas, que são captadas de forma eficiente pelas camadas convolucionais da rede.

Em contraste, observou-se uma maior taxa de confusão entre as classes mancha bacteriana e mancha verde. Essa sobreposição visual deve-se à semelhança de coloração e textura entre as lesões, o que torna o processo de distinção mais complexo mesmo para modelos profundos. Essa dificuldade já foi relatada em estudos semelhantes, como o de Ferentinos (2018), onde sintomas com características visuais semelhantes resultaram em diminuições pontuais de precisão.

Uma abordagem promissora para mitigar esse problema consiste na utilização de técnicas de interpretabilidade, como os mapas de activação Grad-CAM (Gradient-weighted Class Activation Mapping). Essa técnica permite visualizar as regiões da imagem que mais influenciaram a decisão do modelo, possibilitando identificar quais padrões visuais contribuíram para a confusão entre determinadas classes.

A aplicação de Grad-CAM poderá aumentar a transparência do sistema e melhorar a confiança do utilizador no diagnóstico automático, além de auxiliar na identificação de limitações do modelo e na optimização futura do conjunto de dados.

Apesar dessas confusões pontuais, o desempenho global manteve-se elevado, com médias ponderadas de precisão e *recall* acima de 93 %. Isso indica que o modelo é robusto e confiável na detecção automática de doenças da mandioca, apresentando apenas pequenas limitações em classes com elevada semelhança visual.

Além disso, a análise qualitativa revelou que o modelo foi capaz de reconhecer correctamente imagens capturadas sob diferentes condições de iluminação, o que demonstra boa generalização, mesmo fora do ambiente controlado do dataset. Esse comportamento é crucial para aplicações em campo, onde as condições de luz, ângulo e ruído variam significativamente.

De forma geral, os resultados por classe confirmam a eficácia da abordagem baseada em *deep learning* para diagnóstico de doenças em folhas de mandioca. As taxas de acerto obtidas indicam que o modelo é capaz de substituir parcialmente a inspecção humana, reduzindo erros subjectivos e acelerando o processo de diagnóstico em contextos agrícolas locais.

4.4. Resultados da Solução Desenvolvida

Após a selecção da MobileNetV2 como arquitectura final, procedeu-se à integração do modelo treinado numa aplicação móvel desenvolvida em Flutter. O objectivo foi disponibilizar uma solução prática e acessível para o diagnóstico automático de doenças da mandioca em dispositivos móveis.

A aplicação permite capturar ou seleccionar imagens de folhas de mandioca, efectuar o processamento automático da imagem e apresentar a classificação correspondente à doença identificada.




Figura 27: Tela inicial

Nesta tela, os utilizadores poderão visualizar as análises anteriores, pesquisar por uma análise anterior pelo nome da doença e/ou fazer uma nova análise clicando no botão de adicionar.




Figura 28: Tela de nova análise

Nesta tela, poderá efectuar uma nova análise, carregando uma nova imagem seja da galeria ou tirando uma foto pela câmara e de seguida, clicar no iniciar análise para poder obter o resultado.




Figura 29: Tela de resultado da análise

Nesta tela, poderá visualizar o resultado da análise feita previamente, após clicar no iniciar análise na tela de nova análise ou a partir da tela inicial, ao clicar numa análise para ver detalhes.

O tempo de resposta manteve-se reduzido, demonstrando a viabilidade da execução do modelo em ambiente móvel. A utilização da MobileNetV2 contribuiu significativamente para a eficiência da solução, devido ao seu baixo custo computacional e tamanho reduzido.




Figura 30: Tela de apagar e partilhar análise

Ao clicar nos três pontinhos numa análise, poderá ter a opção de partilhar e apagar uma análise feita anteriormente.

4.5. Discussão dos Resultados

Os resultados obtidos ao longo desta investigação demonstram de forma consistente a eficácia das redes neurais convolucionais (CNNs) para a detecção e classificação automática de doenças em folhas de mandioca. Mesmo com um conjunto de dados relativamente limitado e heterogêneo, as diferentes arquitecturas testadas apresentaram desempenhos robustos, validando o potencial do *deep learning* em contextos agrícolas de países em desenvolvimento.

A CNN desenvolvida do zero permitiu compreender a dinâmica de aprendizagem sem dependência de pesos pré-treinados, alcançando aproximadamente 89% de acurácia. Embora funcional, apresentou

maior variabilidade e convergência mais lenta, comportamento relacionado à sensibilidade dos modelos supervisionados ao volume e diversidade dos dados, conforme sublinhado por Bishop (2006). Esta arquitectura desempenhou um papel crucial como referência experimental, evidenciando as limitações de modelos construídos do zero quando se dispõe de conjuntos de dados modestos.

Em contraste, os modelos baseados em *transfer learning*, MobileNetV2 e ResNet50, apresentaram melhorias expressivas em acurácia, estabilidade e velocidade de convergência. A reutilização de pesos treinados no ImageNet permitiu que estes modelos partissem de representações visuais já consolidadas, reduzindo a necessidade de treino intensivo e mitigando os efeitos da escassez de dados, o que corrobora investigações como as de Ferentinos (2018), Ramcharan et al. (2017) e Hughes & Salathé (2015), que também reportam ganhos superiores a 90% em tarefas agrícolas similares.

Entre as arquitecturas avaliadas, a MobileNetV2 destacou-se como a melhor solução prática, atingindo 93.8% de acurácia com menor custo computacional e tamanho de modelo reduzido. A sua leveza e eficiência tornam-na particularmente adequada para aplicações móveis e ambientes com recursos computacionais limitados, atendendo directamente ao objectivo deste trabalho, desenvolver uma solução viável para diagnóstico de doenças em campo, mesmo em regiões rurais com infraestrutura tecnológica reduzida. Essa compatibilidade com dispositivos móveis reforça o potencial de democratização do acesso a tecnologias digitais, contribuindo para a resiliência do sector agrícola moçambicano.

A ResNet50 obteve a maior acurácia absoluta (94.6%), mas o seu peso computacional elevado (mais de 100 MB) e tempo de treino prolongado tornam a sua aplicação impraticável em dispositivos móveis, embora seja uma opção robusta para ambientes laboratoriais ou servidores. Assim, a escolha entre ResNet50 e MobileNetV2 depende do equilíbrio entre precisão e eficiência, um dilema recorrente na literatura de *Edge AI* aplicada à agricultura (Howard et al., 2019).

Apesar da ResNet50 apresentar a maior acurácia global (94.6%), a diferença em relação à MobileNetV2 foi de apenas 0.8 pontos percentuais. Em contrapartida, a ResNet50 apresentou maior custo computacional, com tempo médio de treino significativamente superior e tamanho de modelo acima de 100 MB, enquanto a MobileNetV2 manteve-se abaixo de 15 MB.

Em testes experimentais, observou-se que o tempo médio de inferência da ResNet50 foi aproximadamente três vezes superior ao da MobileNetV2, o que compromete a utilização em tempo real em dispositivos móveis de baixo custo. Dessa forma, o pequeno ganho em acurácia não compensou a perda de eficiência computacional, especialmente considerando o contexto agrícola moçambicano, caracterizado por limitações de infraestrutura tecnológica e conectividade.

Assim, a MobileNetV2 demonstrou oferecer o melhor equilíbrio entre precisão, velocidade de inferência e viabilidade prática, tornando-se mais adequada para aplicações de diagnóstico agrícola em campo.

Do ponto de vista qualitativo, os modelos apresentaram elevada consistência nas classes “saudável”, “CMD” e “CBSD”, que possuem padrões visuais mais definidos. As confusões observadas entre “mancha bacteriana” e “mancha verde” evidenciam a necessidade de ampliar o dataset com imagens locais que capturem variações reais das condições agroecológicas de Moçambique. Este aspecto reforça a importância de incorporar dados regionais contínuos para melhorar a capacidade de generalização futura dos modelos.

Adicionalmente, deve-se considerar o problema da mudança de domínio (*domain shift*), frequentemente observado em modelos treinados com datasets controlados, como o PlantVillage Dataset. Em ambientes reais de campo, factores como iluminação variável, fundos heterogéneos, sombras, oclusões e diferentes condições agroecológicas podem afectar significativamente o desempenho dos modelos de *deep learning*.

Dessa forma, embora os resultados obtidos sejam promissores, a robustez do sistema em contexto moçambicano dependerá da futura incorporação de imagens capturadas localmente, representando condições reais de cultivo da mandioca. Estratégias como adaptação de domínio (*domain adaptation*), *data augmentation* avançado e aprendizagem contínua poderão contribuir para melhorar a capacidade de generalização do modelo em ambientes reais.

De forma global, os resultados desta investigação confirmam não apenas a viabilidade técnica das CNNs no contexto moçambicano, mas também o seu potencial impacto social e económico. Um sistema de diagnóstico rápido em dispositivos móveis pode reduzir significativamente o tempo de identificação de doenças, evitando perdas agrícolas e contribuindo para os objectivos de segurança alimentar estabelecidos no PEDSA II (2022–2030). Para além disso, a integração de *deep learning* com ferramentas de campo abre caminho para avanços na agricultura de precisão, monitoramento em tempo real e sistemas inteligentes de apoio à decisão.

Para além da precisão técnica, a adopção de sistemas inteligentes no contexto agrícola depende também da confiança dos utilizadores finais. Nesse sentido, técnicas de inteligência artificial explicável (*Explainable AI*) poderão desempenhar um papel importante ao permitir que agricultores e técnicos compreendam parcialmente como o sistema tomou determinada decisão. Essa transparência tende a aumentar a aceitação prática da tecnologia e reduzir a resistência ao uso de sistemas automatizados de diagnóstico.

Em síntese, a presente investigação valida que modelos leves baseados em *transfer learning* oferecem um equilíbrio ideal entre precisão, eficiência e operacionalidade, constituindo uma base sólida para o desenvolvimento de soluções tecnológicas sustentáveis e acessíveis à agricultura moçambicana.

Conclusões e Recomendações

5.1. Conclusões

A presente investigação teve como principal objectivo desenvolver e avaliar um modelo baseado em redes neurais convolucionais (CNNs) capaz de detectar automaticamente doenças em folhas de mandioca, contribuindo para a promoção da agricultura de precisão e o fortalecimento da segurança alimentar em Moçambique.

Os resultados experimentais confirmaram a hipótese inicial de que técnicas de *deep learning*, quando devidamente adaptadas e optimizadas, podem alcançar elevados níveis de precisão mesmo com conjuntos de dados limitados. Entre as arquitecturas testadas, a MobileNetV2 destacou-se como o modelo mais equilibrado, combinando alto desempenho (acurácia superior a 93%), baixo custo computacional e viabilidade de execução em dispositivos móveis. Essa característica cumpre integralmente o objectivo de criar uma solução prática, acessível e escalável para uso em contextos agrícolas locais.

A ResNet50 demonstrou o melhor desempenho absoluto (94.6% de acurácia), evidenciando o potencial das redes profundas para reconhecimento de padrões complexos, embora com custo computacional elevado. Por outro lado, a CNN desenvolvida do zero revelou-se uma base experimental valiosa, permitindo validar empiricamente o impacto positivo do *transfer learning* e das estratégias de regularização.

Do ponto de vista científico, este estudo reforça a eficácia das CNNs em tarefas de classificação agrícola, alinhando-se a pesquisas internacionais que comprovam o potencial do *deep learning* na detecção de doenças em plantas. A principal contribuição deste trabalho está na adaptação de um modelo leve e eficiente ao contexto moçambicano, validando a aplicabilidade de soluções tecnológicas acessíveis em ambientes com infraestrutura limitada.

Do ponto de vista prático, o modelo desenvolvido apresenta potencial para apoiar agricultores, técnicos e agentes de extensão rural na identificação precoce de doenças da mandioca, permitindo uma resposta mais rápida e eficaz na gestão fitossanitária. A adopção de ferramentas como esta pode reduzir perdas de produtividade, optimizar o uso de insumos e promover práticas agrícolas mais sustentáveis.

O estudo também contribui para o avanço da agricultura digital em Moçambique, em consonância com as orientações do Plano Estratégico de Desenvolvimento do Sector Agrário (PEDSA II 2022–2030), que enfatiza a importância da inovação tecnológica e da integração das TICs no sector.

Em síntese, conclui-se que os modelos baseados em *deep learning* oferecem uma solução promissora, de baixo custo e alto impacto, para o diagnóstico automático de doenças agrícolas. A combinação de eficiência, precisão e aplicabilidade prática torna o sistema desenvolvido um passo concreto rumo à modernização da agricultura moçambicana, promovendo a transformação digital e a sustentabilidade produtiva no país.

5.2. Limitações e Recomendações

Embora os resultados alcançados tenham sido expressivos e confirmem a viabilidade técnica do modelo proposto, esta investigação apresenta algumas limitações que devem ser reconhecidas e que abrem espaço para aperfeiçoamentos em estudos futuros.

A primeira limitação refere-se à origem do conjunto de dados utilizado. As imagens empregadas foram extraídas de bases públicas (como o *PlantVillage Dataset*), que contêm amostras obtidas em condições laboratoriais ou controladas. Apesar de adequadas para a fase de treino, essas imagens não representam integralmente as condições reais dos campos agrícolas moçambicanos, onde a iluminação, a textura das folhas e o tipo de solo variam significativamente. Assim, a utilização de imagens locais, capturadas em diferentes províncias e estações agrícolas, poderá melhorar a generalização do modelo e torná-lo mais adaptado à realidade nacional.

Outra limitação está relacionada aos recursos computacionais disponíveis. O treino dos modelos foi realizado em ambiente de hardware limitado (MacBook Air M2 e Google Colab), o que restringiu o número de épocas e a experimentação com arquitecturas mais profundas. O acesso a infraestruturas com maior capacidade de processamento, como GPUs dedicadas ou clusters de computação, permitiria explorar configurações mais complexas e otimizar ainda mais o desempenho.

Além disso, o estudo concentrou-se exclusivamente em imagens de folhas de mandioca, não abrangendo outros órgãos da planta (como caules e raízes), que também podem apresentar sintomas relevantes para o diagnóstico de doenças. Trabalhos futuros poderão ampliar o escopo do modelo, incorporando múltiplas fontes de informação visual e até mesmo dados espectrais ou sensores IoT, promovendo uma visão mais completa da saúde das culturas.

Em termos de perspectivas futuras, destacam-se as seguintes direcções de investigação:

- **Colecção e curadoria de imagens locais**, para criação de uma base de dados moçambicana de doenças agrícolas;
- **Integração com sensores de campo (IoT)**, permitindo o monitoramento contínuo da cultura;
- **Uso de técnicas emergentes**, como *Vision Transformers (ViT)* e *lightweight hybrid models*, que prometem melhor equilíbrio entre desempenho e eficiência;
- **Colaboração institucional**, envolvendo universidades, centros de investigação agrícola e o Ministério da Agricultura, para validação do sistema em ambiente real e disseminação a nível nacional.

Em suma, as limitações aqui reconhecidas não diminuem o valor científico da investigação; pelo contrário, delineiam um caminho claro de continuidade e amadurecimento do estudo. As propostas apresentadas constituem oportunidades de evolução que podem ampliar o impacto social, económico e tecnológico deste trabalho, consolidando Moçambique como referência na aplicação de inteligência artificial ao sector agrícola.

Referências Bibliográficas

- ALPAYDIN, E. (2020). *Introduction to machine learning*. 4. ed. Cambridge: MIT Press.
- BANCO MUNDIAL. (2018). *Agriculture sector review: Mozambique*. Washington, DC: World Bank.
- BEBBER, D. P. (2022). Plant disease and food security in the 21st century. *Annual Review of Phytopathology*, **60**: 1–23.
- BISHOP, C. M. (2006). *Pattern recognition and machine learning*. New York: Springer.
- CAROLLO, C. (2016). *Fitopatologia: princípios e conceitos*. São Paulo: Editora Agronômica.
- CCARDESA. (2022). *Digital agriculture country study – Mozambique*. Gaborone: CCARDESA. Acedido em: 25 de Agosto de 2025, em: [CCARDESA Digital Agriculture Country Study – Mozambique](#)
- CRESWELL, J. W. (2014). *Research design: Qualitative, quantitative and mixed methods approaches*. 4. ed. Thousand Oaks: SAGE Publications.
- FAO. (2014). *Moçambique proíbe pesticidas muito perigosos*. Acedido em: 25 de Agosto de 2025, em: [FAO – Moçambique proíbe pesticidas muito perigosos](#)
- FAO. (2020). *The state of food security and nutrition in the world 2020*. Rome: Food and Agriculture Organization of the United Nations.
- FAO. (2021). *Cassava development strategy for Southern Africa*. Rome: Food and Agriculture Organization of the United Nations.
- FAO. (2022). *Mozambique: Country programming framework 2022–2026*. Rome: Food and Agriculture Organization of the United Nations. Acedido em: 25 de Agosto de 2025, em: [FAO Mozambique Country Programming Framework 2022–2026](#)

- FAWCETT, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, **27**: 861–874.
- FONSECA, J. J. S. (2002). *Metodologia da pesquisa científica*. Fortaleza: UEC.
- FERENTINOS, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, **145**: 311–318.
- FUTUREWATER. (2017). *ThirdEye Mozambique: Using drones for smallholder agriculture*. Wageningen: FutureWater Report.
- GIL, A. C. (2002). *Métodos e técnicas de pesquisa social*. 5. ed. São Paulo: Atlas.
- GONÇALVES, L. S. (2006). *Sistema de informações gerenciais*. Curitiba: IESDE Brasil.
- GERHARDT, T. E. e SILVEIRA, D. T. (2009). *Métodos de pesquisa*. Porto Alegre: UFRGS.
- GOODFELLOW, I., BENGIO, Y. e COURVILLE, A. (2016). *Deep learning*. Cambridge: MIT Press.
- HASTIE, T., TIBSHIRANI, R. e FRIEDMAN, J. (2009). *The elements of statistical learning*. 2. ed. New York: Springer.
- HAGUETTE, T. M. F. (1997). *Metodologias qualitativas na sociologia*. 5. ed. Petrópolis: Vozes.
- HE, K., ZHANG, X., REN, S. e SUN, J. (2016). Deep residual learning for image recognition. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Las Vegas: IEEE. pp. 770–778.
- HILLOCKS, R. J. e JENNINGS, D. L. (2003). Cassava brown streak disease: A review of present knowledge and research needs. *International Journal of Pest Management*, **49**(3): 225–234.
- HOWARD, A. et al. (2019). Searching for MobileNetV3. In: *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*. Seoul: IEEE. pp. 1314–1324.
- HUGHES, D. P. e SALATHÉ, M. (2015). An open access repository of images on plant health to enable the development of mobile disease diagnostics. *arXiv preprint arXiv:1511.08060*.
- IITA – INTERNATIONAL INSTITUTE OF TROPICAL AGRICULTURE. (2019). *Major diseases and pests affecting cassava in Africa*. Ibadan: IITA.

- INE – INSTITUTO NACIONAL DE ESTATÍSTICA. (2023). *Indicadores básicos de agricultura e alimentação 2023*. Maputo: INE.
- IIAM – INSTITUTO DE INVESTIGAÇÃO AGRÁRIA DE MOÇAMBIQUE. (2019). *Relatório sobre perdas agrícolas por doenças e pragas em culturas alimentares*. Maputo: IIAM.
- KINGMA, D. P. e BA, J. (2015). Adam: A method for stochastic optimization. In: *International Conference on Learning Representations (ICLR)*. San Diego.
- KOIRALA, A., WALSH, K., WANG, Z. e MCCARTHY, C. (2019). Deep learning for fruit detection and yield estimation: A review. *Computers and Electronics in Agriculture*, **162**: 219–234. Acedido em: 25 de Agosto de 2025, em: [DOI – Koirala et al. 2019](#)
- LEGG, J. P. e THRESH, J. M. (2000). Cassava virus diseases in Africa. *Plant Virology*, **54**: 541–558.
- LECUN, Y., BOTTOU, L., BENGIO, Y. e HAFFNER, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, **86**(11): 2278–2324.
- LOPES, C. A. e ÁVILA, A. C. (2005). *Doenças de plantas: Conceitos básicos e diagnóstico*. Brasília: Embrapa.
- LUNA, S. V. (2000). *Planejamento de pesquisa: Uma introdução*. São Paulo: EDUC.
- MACONDZO, S. G. F. (2018). *Combinações de culturas alimentares básicas praticadas pelos agregados familiares nas regiões Centro e Norte de Moçambique*. Dissertação de Mestrado em Economia Agrária. Faculdade de Agronomia e Engenharia Florestal, Universidade Eduardo Mondlane, Maputo.
- MADER – MINISTÉRIO DA AGRICULTURA E DESENVOLVIMENTO RURAL. (2022). *Plano Estratégico para o Desenvolvimento do Sector Agrário 2022–2030 (PEDSA II)*. Maputo: MADER.
- MARENGONI, M. (2009). *Processamento de imagens digitais*. São Paulo: Pearson.
- MARR, D. (1982). *Vision: A computational investigation into the human representation and processing of visual information*. Cambridge: MIT Press.
- MARCONI, M. A. e LAKATOS, E. M. (2003). *Fundamentos de metodologia científica*. 5. ed. São Paulo: Atlas.
- MITCHELL, T. M. (1997). *Machine learning*. New York: McGraw-Hill.

- NIJHOFF, J. J. (2014). Desenvolver o sector agrícola. Em: FMI, *Moçambique em ascensão: Construir um novo dia*. Washington, DC: FMI.
- O'BRIEN, J. A. (2004). *Sistemas de informação e as decisões gerenciais na era da internet*. 9. ed. São Paulo: Saraiva.
- PICON, A., ALVAREZ-GILA, A., SEITZ, M., ORTIZ-BARREDO, A., ECHAZARRA, J. e JOHANNES, A. (2018). Deep convolutional neural networks for mobile capture device-based crop disease classification in the wild. *Computers and Electronics in Agriculture*, **161**: 280–290.
- POWERS, D. M. W. (2011). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation. *Journal of Machine Learning Technologies*, **2**(1): 37–63.
- PRODANOV, C. e FREITAS, E. C. (2013). *Metodologia do trabalho científico*. Novo Hamburgo: Feevale.
- RAMCHARAN, A. et al. (2017). Deep learning for image-based cassava disease detection. *Frontiers in Plant Science*, **8**: 1852.
- RAMCHARAN, A. et al. (2019). A mobile-based deep learning model for cassava disease diagnosis. *Frontiers in Plant Science*, **10**: 272.
- RUSSELL, S. e NORVIG, P. (2010). *Artificial intelligence: A modern approach*. 3. ed. Upper Saddle River: Prentice Hall.
- SAVARY, S. et al. (2019). The global burden of pathogens and pests on major food crops. *Nature Ecology & Evolution*, **3**: 430–439. Acedido em: 25 de Agosto de 2025, em: [DOI – Savary et al. 2019](#)
- SCHWABER, K. e SUTHERLAND, J. (2020). *The Scrum Guide*. Scrum.org.
- SHIRIMA, R. R. et al. (2022). Epidemiological analysis of cassava mosaic and brown streak diseases, and *Bemisia tabaci* in the Comoros Islands. *Viruses*, **14**(10): 2165.
- SHORTEN, C. e KHOSHGOFTAAR, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, **6**(60): 1–48.
- SITOE, T. A. (2014). Os desafios da investigação agrária em Moçambique. *Desenvolvimento em Questão*, **12**(25): 114–145.

SOMMERVILLE, I. (2011). *Engenharia de software*. 9. ed. São Paulo: Pearson.

SRIVASTAVA, N. et al. (2014). Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, **15**: 1929–1958.

SUTTON, R. S. e BARTO, A. G. (2018). *Reinforcement learning: An introduction*. 2. ed. Cambridge: MIT Press.

TENSORFLOW. (2021). *TensorFlow Lite Guide*. Acedido em: 25 de Agosto de 2025, em: [TensorFlow Lite Guide](#)

TOKO, M. (2007). *Survey on cassava pests and diseases in Mozambique*. Maputo: Ministry of Agriculture – Department of Plant Protection. Acedido em: 25 de Agosto de 2025, em: [Survey on cassava pests and diseases in Mozambique](#)

UEM – UNIVERSIDADE EDUARDO MONDLANE. (2023). *UEM busca soluções para agricultura*. Jornal da UEM.

WORLD BANK. (2021). *ICT in agriculture: Connecting smallholders to knowledge, networks, and institutions*. Washington, DC: World Bank.

WORLD BANK. (2024). *Mozambique economic update 2024*. Washington, DC: World Bank.

ZHOU, X. et al. (2017). Monitoring crop water stress using hyperspectral imagery and machine learning. *Remote Sensing*, **9**(4): 347. Acedido em: 25 de Agosto de 2025, em: [DOI – Zhou et al. 2017](#)