

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

ARTUR JEFFERSON FARIAS DA SILVA

**RECONHECIMENTO DE ESPÉCIES FLORESTAIS DO BIOMA AMAZÔNICO,
UTILIZANDO TÉCNICAS DE DEEP LEARNING**

MEDIANEIRA

2025

ARTUR JEFFERSON FARIAS DA SILVA

**RECONHECIMENTO DE ESPÉCIES FLORESTAIS DO BIOMA AMAZÔNICO,
UTILIZANDO TÉCNICAS DE DEEP LEARNING**

**Recognition of forest species in the Amazon Biome using deep learning
techniques**

Trabalho de Conclusão de Curso de Graduação apresentado como requisito para obtenção do título de Bacharel em Ciência da Computação do Curso de Bacharelado em Ciência da Computação da Universidade Tecnológica Federal do Paraná.

Orientador: Prof. Dr. Pedro Luiz de Paula Filho

Coorientador: Prof^a. Dr^a Silvana Nisgoski

MEDIANEIRA

2025



[4.0 Internacional](https://creativecommons.org/licenses/by-nc-sa/4.0/)

Esta licença permite remixe, adaptação e criação a partir do trabalho, para fins não comerciais, desde que sejam atribuídos créditos ao(s) autor(es) e que licenciem as novas criações sob termos idênticos. Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

ARTUR JEFFERSON FARIAS DA SILVA

**RECONHECIMENTO DE ESPÉCIES FLORESTAIS DO BIOMA AMAZÔNICO,
UTILIZANDO TÉCNICAS DE DEEP LEARNING**

Trabalho de Conclusão de Curso de Graduação
apresentado como requisito para obtenção do
título de Bacharel em Ciência da Computação
do Curso de Bacharelado em Ciência da
Computação da Universidade Tecnológica
Federal do Paraná.

Data de aprovação: 14/Fevereiro/2025

Pedro Luiz de Paula
Prof. Dr
Universidade Tecnológica Federal do Paraná

Alessandra Bortoletto Garbelotti Hoffmann
Prof^ª. Dra
Universidade Tecnológica Federal do Paraná

Kelyn Schenatto
Prof^ª. Dra
Universidade Tecnológica Federal do Paraná

**MEDIANEIRA
2025**

Dedico este trabalho à minha família e amigos,
pelos momentos de ausência.

AGRADECIMENTOS

Ao meu orientador, o Prof. Dr. Pedro Luiz de Paula Filho, pela oportunidade, pela paciência que demonstrou comigo ao longo de toda essa jornada e por sua orientação.

RESUMO

Os biomas de floresta tropical, presentes na América do Sul, África e Ásia, são ecossistemas fundamentais devido à sua biodiversidade, clima quente e alta umidade. A floresta Amazônica, compartilhada por nove países sul-americanos, é um dos exemplos mais notáveis desse bioma. No entanto, enfrenta ameaças crescentes devido ao desmatamento e incêndios florestais, impulsionados pela expansão econômica e exploração madeireira ilegal. Essa degradação compromete a capacidade da floresta de regular o clima global, capturar dióxido de carbono (CO_2) e preservar sua biodiversidade. A identificação precisa das espécies arbóreas exploradas ilegalmente é essencial para mitigar esses impactos, mas os métodos convencionais são demorados e suscetíveis a erros. Nesse contexto, técnicas de aprendizado de máquina vêm sendo exploradas para reconhecimento automatizado de espécies. No entanto, a similaridade entre espécies representa um desafio adicional. Este estudo avalia o uso de *Deep Learning* (DL) para a identificação de espécies florestais na Amazônia, empregando o modelo YOLOv8. O modelo foi treinado com imagens macroscópicas transversais e tangenciais, combinadas com características organolépticas, visando melhorar a precisão da classificação. Os resultados indicam que a fusão dessas informações reduziu erros críticos de predição e aumentou a confiabilidade do modelo. O menor desempenho foi observado no modelo Tangencial, com acurácia de 0,992, enquanto o Modelo Híbrido com Características Organolépticas apresentou o melhor resultado, atingindo 0,999. A robustez do modelo foi confirmada mesmo em condições adversas, como ruído e variações de iluminação, destacando sua aplicabilidade no monitoramento ambiental. A tecnologia proposta representa um avanço significativo na automação da fiscalização ambiental, contribuindo para o combate ao desmatamento ilegal e para a conservação da floresta Amazônica.

Palavras-chave: floresta tropical; amazônia; desmatamento; espécies arbóreas; reconhecimento de espécies.

ABSTRACT

Tropical forest biomes, found in South America, Africa, and Asia, are fundamental ecosystems due to their biodiversity, warm climate, and high humidity. The Amazon Rainforest, shared by nine South American countries, is one of the most notable examples of this biome. However, it faces increasing threats due to deforestation and wildfires, driven by economic expansion and illegal logging. This degradation compromises the forest's ability to regulate the global climate, capture carbon dioxide (CO_2), and preserve its biodiversity. Accurate identification of illegally exploited tree species is essential to mitigate these impacts, but conventional methods are time-consuming and prone to errors. In this context, machine learning techniques have been explored for automated species recognition. However, the similarity between species presents an additional challenge. This study evaluates the use of *Deep Learning* (DL) for forest species identification in the Amazon, employing the YOLOv8 model. The model was trained with macroscopic transverse and tangential images, combined with organoleptic characteristics, aiming to improve classification accuracy. The results indicate that fusing these data reduced critical prediction errors and increased model reliability. The lowest performance was observed in the Tangential model, with an accuracy of 0,992, while the Hybrid Model with Organoleptic Characteristics achieved the best result, reaching 0,999. The model's robustness was confirmed even under adverse conditions, such as noise and lighting variations, highlighting its applicability in environmental monitoring. The proposed technology represents a significant advancement in automating environmental enforcement, contributing to the fight against illegal deforestation and the conservation of the Amazon Rainforest.

Keywords: tropical forest; amazon; deforestation; tree species; species recognition.

LISTA DE FIGURAS

Figura 1 – Imagens das estruturas anatômicas de coníferas e elementos estruturais da madeira.	20
Figura 2 – Tipos de Cortes	21
Figura 3 – Fluxo de trabalho geral de classificação de imagens usando modelos de aprendizado de máquina convencional e aprendizado profundo, respectivamente.	28
Figura 4 – A arquitetura dos detectores de objetos modernos.	29
Figura 5 – Exemplo de Imagens de Treinamento com Regiões Irrelevantes Mascadas.	32
Figura 6 – Amostras tangenciais do <i>Dataset</i> criado.	40
Figura 7 – Amostras transversais do <i>Dataset</i> criado.	40
Figura 8 – Fluxograma das atividades.	42
Figura 9 – Modelos Híbridos com Característica Organoléptica.	45
Figura 10 – Treinamento e Validação para o Modelo Transversal.	50
Figura 11 – Matriz de Confusão para o Modelo Transversal.	51
Figura 12 – Matriz de confusão não normalizada	52
Figura 13 – Espécie Maçaranduba confundida com Castanha de Macaco.	53
Figura 14 – Espécie Castanha de Macaco.	53
Figura 15 – Treinamento e Validação para o Modelo Tangencial.	54
Figura 16 – Matriz de Confusão para o Modelo Tangencial.	54
Figura 17 – Matriz de confusão não normalizada	56
Figura 18 – Espécie Maçaranduba confundida com Angelim Vermelho.	57
Figura 19 – Espécie Garapa confundida com outras Espécies.	57
Figura 20 – Espécie Angelim Vermelho.	58
Figura 21 – Espécie Angelim Vermelho e Mogno.	58
Figura 22 – Espécie Angelim Vermelho.	59
Figura 23 – Espécie Muiracatiara.	59
Figura 24 – Espécie Cupiúba.	60
Figura 25 – Espécie Pariri.	60
Figura 26 – Treinamento e Validação para o Modelo Híbrido.	61

Figura 27 – Matriz de Confusão Normalizada para o Modelo Híbrido.	62
Figura 28 – Matriz de confusão	64
Figura 29 – Espécie Híbrida.	65
Figura 30 – Espécie Imbuia.	65
Figura 31 – Treinamento e Validação para o Modelo Transversal com Características Organolépticas.	66
Figura 32 – Matriz de Confusão para o Modelo Transversal com Características Organolépticas.	66
Figura 33 – Espécie Híbrida Pariri confundida com Maçaranduba.	68
Figura 34 – Espécie Pariri classificada erroneamente como Maçaranduba.	69
Figura 35 – Espécie Maçaranduba.	69
Figura 36 – Matriz de Confusão para o Modelo Tangencial com Características Organolépticas.	70
Figura 37 – Matriz de Confusão para o Modelo Tangencial com Características Organolépticas.	71
Figura 38 – Matriz de confusão não normalizada	72
Figura 39 – Espécie Pariri classificada erroneamente como Maçaranduba.	73
Figura 40 – Espécie Maçaranduba.	73
Figura 41 – Espécie Pariri classificada erroneamente como Imbuia e Sucupira Preta.	74
Figura 42 – Espécie Imbuia e Sucupira Preta.	74
Figura 43 – Espécie Cupiúba classificada erroneamente como Imbuia Pariri.	75
Figura 44 – Espécie Pariri.	75
Figura 45 – Treinamento e Validação para o Modelo Híbrido com Características Organolépticas.	76
Figura 46 – Matriz de Confusão Normalizada para o Modelo Híbrido.	77
Figura 47 – Matriz de confusão não normalizada	79

LISTA DE TABELAS

Tabela 1 – Marcos importantes na história das redes neurais e do aprendizado de máquina.	27
Tabela 2 – Comparações entre os resultados	37
Tabela 3 – Nomes das Espécies Florestais.	41
Tabela 4 – Nomes das espécies com densidade e dureza Janka	44
Tabela 5 – Resumo das Predições e Imagens Processadas para o Modelo Transversal.	51
Tabela 6 – Resumo das Predições e Imagens Processadas para o Modelo Tangencial.	55
Tabela 7 – Resumo das Predições e Imagens Processadas para o Modelo Híbrido.	63
Tabela 8 – Resumo das Predições e Imagens Processadas para o Modelo Transversal com características organolépticas.	67
Tabela 9 – Resumo das Predições e Imagens Processadas para o Modelo Tangencial com Características Organolépticas.	71
Tabela 10 – Resumo das Predições e Imagens Processadas para o Modelo Híbrido com Características Organolépticas.	78
Tabela 11 – Média de probabilidade das predições para cada espécie nos diferentes modelos.	80

LISTA DE ABREVIATURAS E SIGLAS

Siglas

CNN	<i>Convolutional Neural Network</i>
Colab	<i>Google Colaboratory</i>
CPU	<i>Central Processing Unit</i>
CSP	<i>Cross Partial Stage</i>
DL	<i>Deep Learning</i>
ELAN	<i>Efficient Layer Aggregation Network</i>
GLCM	<i>Gray Level Co-occurrence Matriz</i>
GPU	<i>Graphics Processing Unit</i>
IA	Inteligência Artificial
IBAMA	Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis
LBP	<i>Local Binary Patterns</i>
LPQ	<i>Local Phase Quantization</i>
ML	<i>Machine Learning</i>
PDI	Processamento Digital de Imagens
PF	Polícia Federal
PRF	Polícia Rodoviária Federal
RAM	<i>Random Access Memory</i>
ResNet-50	<i>50-layer convolutional neural network</i>
SVM	<i>Support Vector Machines</i>
TL	<i>Transfer Learning</i>
TPU	<i>Tensor Processing Unit</i>
UFPR	Universidade Federal do Paraná

YOLO

You Only Look Once

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Objetivo geral	14
1.1.1	Objetivo específicos	14
1.2	Justificativa	15
2	REFERENCIAL TEÓRICO	16
2.1	Caracterização De Espécies Florestais	16
2.2	A Base da Identificação Macroscópica e Microscópica	18
2.2.1	Característica Macroscópica	18
2.2.2	Características Microscópicas	18
2.3	Tipos de Cortes	20
2.4	Características Organolépticas da Madeira	21
2.5	Dureza - Método Janka	23
2.6	Visão Computacional	23
2.6.1	Processamento de Imagens Digitais	24
2.6.2	Técnicas de Classificação	25
2.6.3	<i>Deep Learning</i>	26
2.7	<i>You Only Look Once</i>	28
2.7.1	Métricas de Avaliação	32
2.7.1.1	<u>Acurácia</u>	32
2.7.1.2	<u>Precisão e Recall</u>	33
2.7.1.3	<u>F1-Score</u>	33
2.7.2	Dados de Treinamento e Validação	34
2.8	Trabalhos Relacionados	35
3	MATERIAIS E MÉTODOS	38
3.1	Materiais	38
3.1.1	Ambiente de desenvolvimento, Bibliotecas e ferramentas	38
3.1.2	Conjunto de Dados	39
3.2	Metodologias	41
3.3	Treinamento do Modelo	42
3.3.1	Base de Dados	42

3.3.2	Dureza - Método Janka	43
3.3.3	Abordagem com CNN	46
3.3.4	Parâmetros de Avaliação	46
4	RESULTADOS E DISCUSSÃO	48
4.1	Treinamento Modelo Transversal	50
4.2	Desempenho do Modelo Transversal	51
4.3	Treinamento Modelo Tangencial	54
4.4	Desempenho do Modelo Tangencial	55
4.5	Treinamento Modelo Híbrido	61
4.6	Desempenho do Modelo Híbrido	62
4.7	Treinamento Modelo Transversal com Características Organolépticas .	65
4.8	Desempenho do Modelo Transversal com Características Organolépticas	67
4.9	Treinamento Modelo Tangencial com Características Organolépticas . .	69
4.10	Desempenho do Modelo Tangencial com Características Organolépticas	71
4.11	Treinamento Modelo Híbrido com Características Organolépticas	76
4.12	Desempenho do Modelo Híbrido com Características Organolépticas . .	77
4.13	Análise dos Modelos	79
5	CONCLUSÃO	81
5.1	Perspectivas Futuras	81
	REFERÊNCIAS	83

1 INTRODUÇÃO

Os ecossistemas desempenham um papel essencial no equilíbrio ambiental e na manutenção da vida na Terra. Eles regulam o clima, sustentam a biodiversidade e fornecem recursos naturais fundamentais para diversas formas de vida, incluindo a humana. Entre os ecossistemas mais ricos e complexos está o Bioma de floresta tropical, caracterizado por alta biodiversidade, clima quente e chuvas abundantes Ghapar *et al.* (2021).

Na América do Sul, a floresta Amazônica é um dos exemplos mais significativos desse Bioma, abrangendo nove países: Brasil, Peru, Bolívia, Colômbia, Equador, Guiana Francesa, Guiana, Suriname e Venezuela. Sua importância é notável devido ao seu papel na mitigação das mudanças climáticas e na regulação do ciclo hidrológico Ellwanger *et al.* (2020), Souza *et al.* (2021). No entanto, esse ecossistema enfrenta ameaças crescentes impulsionadas pela expansão econômica, que tem acelerado sua degradação.

A resiliência da floresta Amazônica diante dessas mudanças é uma grande preocupação, pois, como destacado por Boulton, Lenton e Boers (2022) e Gatti *et al.* (2021), ela é essencial para o controle climático global. Além de capturar grandes quantidades de dióxido de carbono (CO₂), sua vasta cobertura vegetal contribui para a estabilidade da umidade atmosférica e dos padrões de precipitação. Entretanto, esse Bioma está sob risco crescente devido a incêndios, desmatamento e degradação ambiental, processos frequentemente associados à intervenção humana direta e às secas recorrentes Boulton, Lenton e Boers (2022), Souza *et al.* (2021).

A extração ilegal de madeira é um dos principais fatores do desmatamento na Amazônia, devido ao alto valor comercial de suas espécies arbóreas Souza *et al.* (2021). Essa prática resulta em danos irreversíveis às florestas tropicais, levando à perda de biodiversidade e a impactos ambientais severos. Atualmente, a identificação das espécies exploradas é realizada manualmente, tornando o processo demorado e sujeito a erros Paula Filho (2012), Ghapar *et al.* (2021).

Nesse contexto, o uso de aprendizado de máquina tem se mostrado uma solução promissora para a classificação automatizada de espécies arbóreas, auxiliando no combate ao desmatamento ilegal Paula Filho (2012), Neethu e Syla (2021). Diferentes abordagens, como *Support Vector Machines* (SVM), Redes Neurais Artificiais (RNAs) e *K-Nearest Neighbors* (K-NN), têm sido exploradas para essa finalidade. No entanto, a alta similaridade entre espécies em termos de textura, cor, estrutura e cheiro representa um desafio significativo para esses métodos Neethu e Syla (2021).

Recentemente, técnicas mais avançadas, como o uso do YOLOv8, têm demonstrado um desempenho superior na identificação de espécies arbóreas. Estudos indicam que a aplicação do YOLOv8 em imagens de seções longitudinais e múltiplas vistas das principais seções anatômicas da madeira permite uma classificação mais precisa e eficiente Geus *et al.* (2020), Wu

et al. (2021). Esses avanços reduzem significativamente a necessidade de processos manuais, fortalecendo a fiscalização contra a extração ilegal de madeira.

Dessa forma, há um grande potencial na utilização de *Deep Learning* (DL) para aprimorar a precisão do reconhecimento de espécies arbóreas a partir de imagens, contribuindo significativamente para a preservação da floresta Amazônica e para a mitigação do desmatamento ilegal.

1.1 Objetivo geral

Reconhecer espécies florestais do Bioma Amazônico utilizando técnicas de *Deep Learning* (DL) por meio de imagens macroscópicas, transversais e tangenciais, agregando propriedades organolépticas da madeira.

1.1.1 Objetivo específicos

- Criar dois *datasets* de imagens macroscópicas, obtidas por um aparelho de microscópio digital;
- Testar diferentes modelos de DL para os dois diferentes *datasets*;
- Desenvolver um modelo híbrido fundindo as imagens de diferentes cortes (transversal/tangencial);
- Desenvolver um modelo híbrido utilizando informações organolépticas e imagens das madeiras;
- Avaliar a eficiência das diferentes abordagens.

1.2 Justificativa

De acordo com Ellwanger *et al.* (2020) e Malhi *et al.* (2008), a floresta Amazônica é um dos ecossistemas mais importantes da Terra. É o lar de uma vasta diversidade de vida vegetal e animal; ela desempenha um papel vital na regulação do clima global. No entanto, a floresta tropical está ameaçada pelo desmatamento e mudanças no clima, causadas devido a expansão econômica e seca.

Para Paula Filho (2012) e Oliveira (2018), um dos desafios na proteção da floresta Amazônica é identificar as diferentes espécies que ali vivem pelos órgãos responsáveis, tais como Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (IBAMA), Polícia Federal (PF), Polícia Rodoviária Federal (PRF), entre outros. A necessidade de identificar as espécies florestais é essencial para a conservação da floresta Amazônica. Ao identificar as espécies presentes em uma área, é possível entender melhor o ecossistema e como ele funciona. Esta informação pode, então, ser usada para desenvolver práticas de manejo sustentável que protegerão a floresta tropical e sua biodiversidade.

Neethu e Sylva (2021), comentam que a identificação de espécies é feita por especialistas treinados que examinam espécimes físicos de plantas. No entanto, esse processo é demorado e trabalhoso, e nem sempre é possível obter amostras físicas. Porém, avanços recentes na computação tornaram possível desenvolver abordagens automatizadas para a identificação de espécies. Esses métodos usam visão computacional e aprendizado de máquina para identificar espécies a partir de imagens ou outras formas de entrada de dados (GHAPAR *et al.*, 2021; NEETHU; SYLA, 2021; OLIVEIRA, 2018; PAULA FILHO, 2012).

Ainda segundo Oliveira (2018), a exploração ilegal dos recursos florestais é uma grande ameaça, pois essa prática ilegal teve um aumento significativo devido à exploração de seu uso na construção, produção de carvão vegetal, madeira serrada, industrialização e exportação, tornando a regulamentação mais difícil. Estes problemas são agravados pelo fato de as agências governamentais não terem recursos para inspecionar todas as áreas florestais. Desenvolvendo novas tecnologias que possam automatizar o processo de identificação, é possível torná-lo mais eficiente e eficaz. Isso ajudará a garantir uma melhor fiscalização, o que pode auxiliar na proteção da floresta Amazônica.

Dessa forma, esta pesquisa fundamenta a criação de abordagens automatizadas destinadas a reconhecer diferentes espécies presentes na região da Amazônia. Esses métodos podem ser usados por agências governamentais, pesquisadores e conservacionistas para identificar as espécies com mais rapidez e precisão, ajudando os órgãos de fiscalização a desenvolver estratégias de combate a exploração indevida da madeira de forma mais eficaz.

2 REFERENCIAL TEÓRICO

Neste capítulo, serão abordados conceitos bibliográficos fundamentais que servem como base para a pesquisa e os experimentos propostos. Será feita uma revisão técnica de trabalhos anteriores, explorando projetos relacionados ao campo de estudo e analisando os resultados das pesquisas, metodologias empregadas e conclusões alcançadas para compreender o panorama como um todo.

O capítulo é subdividido em vários tópicos, incluindo a anatomia da madeira, abrangendo as perspectivas microscópicas e macroscópicas, os tipos de cortes utilizados na identificação de espécies de madeira e as características organolépticas, como cor, textura, cheiro e sabor. Adicionalmente, são revisadas as mais recentes inovações e técnicas aplicadas à pesquisa da madeira, destacando seu impacto e contribuição para o desenvolvimento do campo. Essa estrutura detalhada proporciona um sólido contexto teórico para orientar e informar a pesquisa em andamento, estabelecendo uma base consistente para os experimentos e descobertas futuras.

A classificação de imagens desempenha um papel central na identificação de espécies arbóreas, pois permite diferenciar padrões visuais com alta precisão. O processo envolve múltiplas etapas, desde o pré-processamento das imagens, passando pela extração de características relevantes, até a classificação propriamente dita. Para isso, são empregados algoritmos de visão computacional, bibliotecas de aprendizado de máquina e técnicas avançadas de aprendizado profundo. Redes neurais convolucionais (*Convolutional Neural Networks* - CNNs) são amplamente utilizadas nesse contexto, exigindo alto poder computacional e uma escolha criteriosa da arquitetura do modelo para garantir resultados precisos e eficientes. A combinação entre fundamentos teóricos e soluções computacionais avançadas é essencial para a obtenção de classificações robustas e confiáveis.

2.1 Caracterização De Espécies Florestais

As características anatômicas da madeira são fundamentais para sua utilização em diversas aplicações. A madeira é um material orgânico altamente complexo e heterogêneo, composto por conjuntos de células com propriedades específicas que desempenham funções vitais, tais como crescimento, condução de água, transformação, armazenamento e transporte de substâncias nutritivas, bem como suporte estrutural para a planta, conforme estudo de Araujo (2020).

Suas propriedades físicas, químicas e mecânicas são influenciadas por diversos fatores, incluindo a espécie da árvore, a região do tronco de em que é extraída, as condições climáticas e o ambiente de crescimento Paula Filho (2012) Araujo (2020).

Segundo os estudos de Araujo (2020), a análise das características anatômicas da madeira é de grande relevância, visto que a madeira é amplamente utilizada em várias áreas da atividade humana. Ela é constituída por diversos tipos de células e tecidos, cada um desem-

penhando funções específicas relacionadas ao transporte de fluidos, transformação, armazenamento e sustentação da planta, como também ressaltado por Botosso (2011) e Paula Filho (2012).

No estudo de Botosso (2011), é destacado que a madeira possui uma estrutura complexa, apresentando características particulares em diferentes partes da árvore. Os anéis de crescimento surgem devido às variações na formação da madeira ao longo do tempo, ou seja, são formados anualmente e refletem o aumento do tronco da árvore. A quantidade de anéis pode ser usada para estimar a idade da árvore. As células iniciais possuem paredes finas e lumens grandes na primavera, enquanto no outono, as células tornam-se mais espessas e os lumens menores, resultando em uma coloração mais escura Paula Filho (2012) Araujo (2020).

O cerne, que representa a parte central do tronco, forma-se à medida que a árvore cresce e suas partes internas perdem vitalidade, adquirindo uma coloração mais escura devido à deposição de substâncias como tanino, resinas e gorduras, como explicado por Paula Filho (2012). Em contrapartida, o alburno, a parte mais externa do tronco, é responsável pelo transporte ascendente de fluidos retirados do solo, conforme mencionado tanto por Araujo (2020) quanto por Paula Filho (2012).

De acordo com as observações de Botosso (2011), a identificação das espécies de árvores produtoras de madeira é essencial, e a anatomia desempenha um papel fundamental nesse processo. Entretanto, durante o processamento da madeira, muitas vezes, características botânicas importantes são removidas ou negligenciadas, o que pode resultar na classificação equivocada das espécies. Nesse contexto, a ciência botânica e a análise das características anatômicas da madeira desempenham um papel fundamental na identificação precisa das espécies.

Conforme ressaltado por Araujo (2020), algumas atividades relacionadas às propriedades físicas e mecânicas da madeira são essenciais para determinar suas aplicações apropriadas. A densidade da madeira, por exemplo, é uma característica tecnológica fundamental, pois está diretamente relacionada à resistência mecânica e a outras propriedades físicas e mecânicas. É importante observar que a madeira é um material anisotrópico, ou seja, suas propriedades de contração e expansão variam nas direções radial, tangencial e longitudinal.

No contexto das características físicas e mecânicas da madeira, o estudo de Araujo (2020) destaca que a madeira é um material higroscópico, ou seja, pode absorver e liberar umidade, resultando em contração e expansão. Além disso, a permeabilidade da madeira também afeta sua capacidade de secagem e preservação, sendo mais desafiador secar ou impregnar madeiras de alta densidade.

Portanto, a anatomia da madeira e suas características físicas e mecânicas desempenham um papel fundamental na identificação precisa das espécies de árvores e na determinação de suas aplicações apropriadas, contribuindo para a utilização sustentável deste recurso natural (ARAUJO, 2020; BOTOSSO, 2011; PAULA FILHO, 2012).

2.2 A Base da Identificação Macroscópica e Microscópica

A madeira tem desempenhado um papel fundamental na história da humanidade desde os tempos mais remotos, sendo utilizada como fonte de energia, material de construção e meio de transporte. Ao longo dos séculos, sua versatilidade consolidou sua importância em diversas áreas, especialmente nas indústrias de celulose, papel e outros setores madeireiros. A identificação precisa das características macroscópicas e microscópicas da madeira é essencial não apenas para o aproveitamento eficiente desses recursos, mas também para a conservação de espécies florestais e o desenvolvimento sustentável.

2.2.1 Característica Macroscópica

A análise da madeira pode ser realizada em escalas macroscópica e microscópica, cada uma com suas particularidades e aplicações. De acordo com Wheeler e Baas (1998), as características macroscópicas são aquelas que podem ser observadas a olho nu ou com o auxílio de uma lupa, incluindo recursos físicos como cor e brilho. A cor da madeira pode variar de espécie para espécie, e até mesmo dentro da mesma árvore. Além disso, a cor da madeira pode mudar com o tempo e a exposição à luz. O brilho da madeira é outra característica física importante que pode ajudar na sua identificação.

Além das características físicas, Wheeler e Baas (1998) destacam que as características anatômicas macroscópicas também são importantes na identificação da madeira. Estas incluem a porosidade, a disposição e o agrupamento dos vasos, a disposição e a abundância do parênquima axial, o tamanho dos raios em relação ao diâmetro dos vasos, a altura dos raios e a presença ou ausência de estrutura riscada, entre outros. A disposição dos vasos pode ser um indicador importante do tipo de madeira.

Portanto, a análise macroscópica da madeira é um processo detalhado que envolve a observação cuidadosa de várias características físicas e anatômicas. Cada espécie de madeira tem seu próprio conjunto único de características que a torna distinta das demais. Portanto, um entendimento profundo dessas características é essencial para a identificação precisa da madeira.

2.2.2 Características Microscópicas

A análise microscópica da madeira desempenha um papel fundamental na identificação e caracterização de sua estrutura, permitindo uma compreensão detalhada de suas características e particularidades. Isso envolve a observação de características anatômicas microscópicas, que são essenciais para a identificação e utilização adequada da madeira (BOTOSSO, 2011; OLIVEIRA, 2018).

Sob um microscópio, a estrutura do tronco de uma árvore é composta por uma miríade de células lenhosas individuais, cada uma apresentando características particulares as quais são moldadas por sua função específica dentro do organismo arbóreo. Essas células podem ser agrupadas em categorias distintas, abrangendo traqueóides, vasos, fibras e raios medulares (SANTOS, 2015).

Além disso, Oliveira (2018) aponta que as características anatômicas microscópicas da madeira são aquelas que requerem o uso de um microscópio para serem observadas. Estas incluem a estrutura celular da madeira, composta por milhões de células microscópicas de diferentes tamanhos e formas. Estas células são divididas em vários grupos, incluindo traqueídeos, vasos, fibras e raios medulares. Cada um desses grupos de células desempenha um papel importante na estrutura e função da madeira.

Abaixo estão listadas as características, a Figura 1 ilustra a estrutura de um tronco, conforme estudos realizados por Santos (2015)

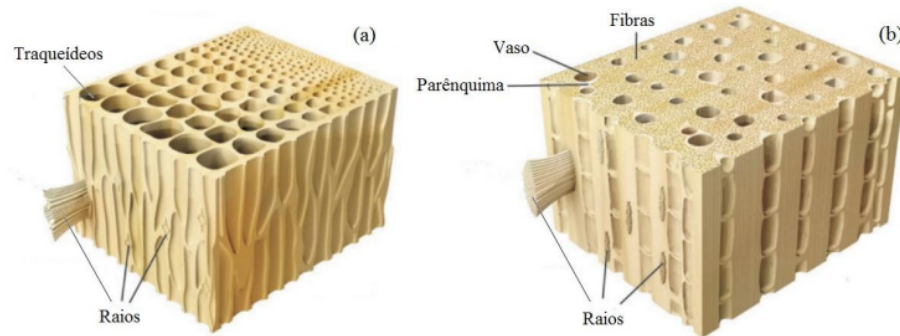
- **Traqueóides** Células alongadas, até 5,0 mm de comprimento e diâmetro de 0,06 mm. Sua função é: conduzir seiva bruta, depósito de substâncias polimerizadas, conferir resistência mecânica (coníferas).
- **Vasos:** Células longas, até 1,0 mm de comprimento, 0,3 mm de diâmetro, seção arredondada e vazada. Sua função é conduzir seiva bruta, depósito de materiais polimerizados (folhosas).
- **Fibras:** Células longas, até 1,5 mm de comprimento, parede grossa, seção arredondada e vazada. Tem a função de dar resistência mecânica, rigidez (folhosas).
- **Raios Medulares:** Células longas, achatadas, dispostas horizontalmente. Cujas função de conduzir seiva elaborada (coníferas).

A Figura 1(a) ilustra as estruturas anatômicas típicas das coníferas, destacando as traqueóides como os principais elementos responsáveis pela condução da seiva bruta e pelo suporte mecânico. Além disso, é possível observar os raios medulares, que desempenham a função de transporte lateral de nutrientes.

Já a Figura 1(b) apresenta os elementos estruturais da madeira de forma geral, incluindo tanto as fibras quanto os vasos. Os vasos são responsáveis pela condução eficiente da seiva bruta, enquanto as fibras conferem resistência e rigidez ao tecido lenhoso.

É importante ressaltar que a análise microscópica da madeira envolve diferentes cortes da lâmina histológica, como o corte transversal, o corte longitudinal tangencial e o corte longitudinal radial, cada um permitindo a análise de aspectos específicos da madeira, como a presença de camadas de crescimento, arranjo de células, porosidade e características dos raios (PAULA FILHO, 2012).

Figura 1 – Imagens das estruturas anatômicas de coníferas e elementos estruturais da madeira.



Fonte: Santos (2015).

Em conjunto, essa abordagem microscópica fornece um panorama completo das estruturas microscópicas da madeira, o que é essencial para sua identificação precisa e utilização adequada em diversas aplicações, além de contribuir para a gestão sustentável desse importante recurso natural (BOTOSSO, 2011; OLIVEIRA, 2018; PAULA FILHO, 2012; SANTOS, 2015).

2.3 Tipos de Cortes


Segundo Burger e Richter (1991), a análise microscópica e macroscópica da madeira desempenha um papel fundamental na compreensão de sua estrutura anatômica complexa e heterogênea. Um fator essencial a ser considerado durante essa análise é a escolha do tipo de corte ou plano de observação, pois a aparência da madeira, assim como suas propriedades físicas e mecânicas, pode variar significativamente conforme a orientação das células lenhosas. Isso ocorre porque a madeira é um material anisotrópico, ou seja, suas propriedades mudam de acordo com a direção em que são medidas.

Existem três planos de referência amplamente utilizados na análise anatômica da madeira segundo estudos de Araujo (2020) e Burger e Richter (1991), e esses planos de referência são escolhidos com base na direção das fibras da madeira e na orientação dos anéis de crescimento, sendo eles:

- **Corte Transversal (X):** Este tipo de corte é feito perpendicularmente à direção das fibras da madeira. É também conhecido como corte 90-90, a aresta de corte e a direção do movimento de corte são perpendiculares à direção das fibras.
- **Corte Longitudinal Radial (R):** Este tipo de corte é feito perpendicularmente aos anéis de crescimento. Este método produz veias visíveis e evita empenamento (deformação que dobra a borda da placa) e rachaduras (fendas longitudinais), no entanto, desperdiça mais material.

- **Corte Longitudinal Tangencial (T):** Este corte é realizado paralelamente ao eixo longitudinal da peça de madeira, perpendicular ao raio e ao mesmo tempo tangencial aos anéis de crescimento. Este tipo de corte maximiza a exposição das veias naturais da madeira e, embora não seja o corte mais resistente, é o mais belo e vistoso.

Com o auxílio desses tipos de cortes, é possível reconstruir tridimensionalmente a arquitetura da estrutura anatômica da madeira. A Figura 2 exemplifica os tipos de cortes em um tronco. Além da aparência, também é importante destacar que o comportamento físico-mecânico da madeira varia em cada um desses três sentidos, devido à disposição anisotrópica de suas células. Isso foi demonstrado em estudos como os de Araujo (2020) e Szücs *et al.* (2015), que exploraram como a orientação das células lenhosas pode afetar as propriedades da madeira.



Portanto, ao analisar a madeira, a escolha do corte adequado é fundamental, pois cada corte revela diferentes aspectos da estrutura da madeira. Essas informações são essenciais para entender melhor este recurso natural. Cada tipo de corte fornece dados diferentes, todos importantes para uma análise completa e correta da madeira.

2.4 Características Organolépticas da Madeira

No contexto da madeira, estudos de Araujo (2020) e Paula Filho (2012) dizem que as características organolépticas compreendem aspectos como cor, odor, sabor, textura, brilho, padrão de grã e densidade aparente. Essas propriedades podem ser úteis na identificação e descrição de diferentes tipos de madeira, mas é importante ter em mente que a percepção dessas características pode variar entre diferentes pessoas, tornando a avaliação subjetiva em alguns casos.

As características organolépticas da madeira são uma parte importante da análise e identificação desse material, mas devem ser usadas com cuidado, especialmente quando se trata de gosto e odor, para evitar exposição a substâncias desconhecidas ou potencialmente prejudiciais segundo Araujo (2020).

A seguir, uma descrição detalhada dessas características da madeira, com base em estudos de Araujo (2020) e Burger e Richter (1991).

- **Cor do cerne:** A cor do cerne, a parte mais interna do tronco, muitas vezes se destaca pela sua coloração mais escura ou contrastada em relação à parte externa, chamada alborno. Essa variação de cor ocorre devido à impregnação de substâncias orgânicas, como tanino e resinas, depositadas de forma mais intensa no cerne. Madeiras de cores escuras tendem a ser mais duráveis naturalmente devido a esses produtos, que são tóxicos para insetos e fungos xilófagos. No entanto, a avaliação da cor deve ser feita em superfícies recentemente expostas do cerne, uma vez que a oxidação de componentes orgânicos pode alterar a coloração ao longo do tempo.
- **Gosto:** O gosto da madeira, embora intimamente relacionado ao cheiro, é uma característica útil para confirmar a identidade de algumas espécies. No entanto, raramente o sabor é decisivo na identificação. Para avaliá-lo, pequenas lascas de madeira podem ser mastigadas e posicionadas na língua. Algumas espécies apresentam gostos característicos, como amargura ou adocicado, mas essa avaliação deve ser feita apenas quando se tem certeza de que a madeira não foi tratada quimicamente.
- **Odor:** O odor da madeira pode variar e deve ser verificado em amostras secas, de preferência em superfícies recentemente expostas. Algumas madeiras têm odores distintos, que podem ser agradáveis ou desagradáveis. No entanto, a avaliação precisa do odor requer cuidado, pois é uma característica subjetiva.
- **Grã:** O termo “grã” refere-se à orientação e ao paralelismo dos elementos celulares verticais no lenho em relação ao eixo principal do tronco. A variação na orientação desses tecidos é resultado de influências ambientais e ecológicas, resultando em diferentes tipos de grã, como grãs retas ou irregulares.
- **Textura:** A textura da madeira está relacionada ao aspecto visual e tátil da sua superfície. Nas angiospermas, é determinada principalmente pelo diâmetro dos vasos, enquanto nas gimnospermas, depende do contraste e da espessura dos anéis de crescimento. A textura pode ser lisa, rugosa, macia, áspera ou ondulada.
- **Brilho:** Algumas madeiras apresentam brilho natural, resultado da orientação dos elementos celulares e da presença de extrativos no cerne. No entanto, o brilho é principalmente uma característica estética e não é amplamente usado na identificação de madeiras.
- **Densidade de Massa:** A densidade de massa, ou simplesmente densidade, é uma propriedade importante na tecnologia da madeira. No entanto, também pode ser percebida pelos sentidos humanos, tornando-se útil na identificação. Madeiras leves e pesadas podem ser distinguidas pela sua densidade aparente. Essa característica reflete

a quantidade de matéria lenhosa por unidade de volume, com inclusões e conteúdos diversos podendo afetar o peso da madeira.

2.5 Dureza - Método Janka

Além das métricas de avaliação específicas para modelos de visão computacional, o trabalho também contempla características físicas das espécies florestais, como a dureza, medida pelo Método Janka. Essas propriedades físicas desempenham um papel importante na identificação e caracterização de materiais, complementando a análise baseada em imagens.

A dureza é um conceito fundamental na ciência dos materiais e na mecânica de contato, inicialmente desenvolvido por Heinrich Hertz. Existem diferentes tipos de testes e escalas de dureza, como resistência ao risco, indentação estática e indentação dinâmica. Cada tipo de teste e escala mede a resistência de um material de maneira específica Koczan, Karwat e Kozakiewicz (2021).

Segundo Koczan, Karwat e Kozakiewicz (2021), a dureza da madeira pode ser medida por vários métodos, sendo o Janka um dos mais adequados devido à sua simplicidade. Segundo os mesmos autores, existem outros métodos como os propostos por Brinell, Krippel e Meyer, mas o método Janka é amplamente utilizado para madeiras devido à sua precisão e facilidade de execução. Ele mede a força necessária para embutir parcialmente uma esfera de aço na madeira, fornecendo uma medida direta da resistência da madeira à penetração.

O cálculo da dureza Janka utiliza a área de projeção de indentação. A fórmula principal é apresentada na Equação 1:

$$H_j = \frac{F_{\max}}{S_{\max}} \quad (1)$$

Onde H_j representa a dureza Janka (em MPa), F_{\max} é a força máxima aplicada, e S_{\max} é a área da projeção de indentação. No método Janka, a profundidade de penetração da esfera é usada como critério para medir a dureza, permitindo avaliar a resistência da madeira a forças de compressão que simulam condições reais de uso, segundo Koczan, Karwat e Kozakiewicz (2021).

2.6 Visão Computacional

Segundo Chai *et al.* (2021), a visão computacional é um campo de pesquisa emergente que se concentra na análise visual computacional de imagens e vídeos. Este campo é derivado da ciência da cognição e da Inteligência Artificial (IA), e tem como objetivo principal desenvolver novos modelos para a cognição visual. A visão computacional busca demonstrar uma capacidade visual semelhante a do ser humano, permitindo que as máquinas sintam o ambiente em seu campo de visão, compreendam o que está sendo sentido e realizem ações com base

nessa compreensão. Oliveira (2018) diz que a visão computacional não está restrita a um único campo de aplicação. Ela tem um alcance amplo e pode ser utilizada em diversas áreas, como Agronomia, Biologia, Medicina e dentre outras. Esse campo é construído sobre a integração de técnicas de Processamento Digital de Imagens (PDI) e IA, permitindo a análise, manipulação e interpretação de informações visuais contidas em imagens digitais.

Por fim, nota-se que a visão computacional representa um campo multidisciplinar que busca capacitar sistemas computacionais a processar e compreender informações visuais, com aplicações abrangentes em várias áreas do conhecimento. O uso crescente de técnicas de DL tem impulsionado avanços significativos nessa área, tornando-a cada vez mais relevante e impactante.

2.6.1 Processamento de Imagens Digitais

Para Oliveira (2018), o PDI é um campo da visão computacional, também se concentra na extração de características de imagens digitais. Ele abrange técnicas para aprimorar a informação visual, incluindo transformações estruturais e manipulações nos canais de cores e no histograma da imagem.

Segundo Hwang e Sugiyama (2021), essa área é semelhante ao trabalho dos anatomistas de madeira, que observam as características anatômicas dos tecidos de madeira para identificar tipos de madeira. No entanto, em vez de olhar para fibras de madeira e células, o PDI extrai características como pontos, manchas, cantos e bordas das imagens. Ainda segundo o mesmo, para os computadores, uma imagem é uma matriz de números, cada número representa a intensidade de um pixel. As imagens de madeira são compostas por vários tipos de células, e diferentes espécies de madeira têm padrões distintos de elementos anatômicos. Essas diferenças em intensidade de pixel, arranjo, distribuição e padrões de agregação são detectadas pela visão computacional e aprendidas por meio de *Machine Learning* (ML).

De acordo com a Luo, Hao e Tong (2018), a tecnologia de PDI envolve o uso da computação para eliminar ruídos, aprimorar, segmentar e recuperar imagens. A evolução das redes de computadores e o aumento do nível de matemática desempenharam um papel importante no desenvolvimento dessa tecnologia. No início, na década de 1920, essa tecnologia foi usada para transferir imagens entre o Reino Unido e os Estados Unidos, mas a qualidade das imagens era limitada. Somente na década de 1970, ocorreram atualizações significativas no PDI. À medida que a tecnologia continuou a se aprimorar e foi aplicada em diversas áreas, a demanda por qualidade nas imagens processadas aumentou, estimulando ainda mais o desenvolvimento dessa tecnologia.

2.6.2 Técnicas de Classificação

Ponnusamy, Sathiamoorthy e Kaliyamoorthi (2020), relatam que a classificação de imagens é um processo que envolve a atribuição de uma etiqueta ou rótulo a uma imagem inteira com base em dados de treinamento pré-existentes de imagens já rotuladas. O processo inclui etapas como pré-processamento de imagem, sensores de imagem, detecção de objetos, segmentação de objetos, extração de características e classificação de objetos. Além disso, ele aborda diferenças entre classificação de imagens e detecção de objetos e lista os tipos de técnicas de pré-processamento de imagem.

A classificação de imagens é uma tarefa essencial e desafiadora em vários domínios de aplicação, incluindo sensoriamento remoto, navegação de veículos, imagens biomédicas, videovigilância, biometria, inspeção visual industrial e navegação de robôs, como citado nos estudos de Ponnusamy, Sathiamoorthy e Kaliyamoorthi (2020). Para isso, existem dois métodos principais para classificação de imagens: supervisionado e não supervisionado, segundo os autores.

- **Classificação supervisionada:** Um subconjunto de pixels é rotulado previamente para classes específicas através de treinamento. Um classificador utiliza esses pixels treinados para categorizar outras imagens, o que requer informações prévias coletadas por um analista. O analista seleciona áreas de treinamento representativas para cada classe informativa, e o algoritmo cria fronteiras de decisão. Métodos comuns incluem paralelepípedo que se refere à forma geométrica que é usada para representar as classes no espaço espectral durante a classificação, distância mínima até a média e máxima verossimilhança. As etapas envolvem a identificação das áreas de treinamento, a extração de assinaturas para essas áreas, a classificação de todos os pixels na imagem e a criação de um mapa de classes segundo estudos de Ponnusamy, Sathiamoorthy e Kaliyamoorthi (2020), Oliveira (2018).
- **Classificação não supervisionada:** O processo de classificação de pixels envolve a avaliação de seus vetores de características, que representam suas intensidades em diferentes bandas espectrais. Eles são classificados em classes específicas se seus vetores de características estiverem contidos dentro dos paralelepípedos que representam essas classes.

Por meio de um processo conhecido como agrupamento, os pixels são automaticamente organizados com base em suas propriedades. Esses grupos são chamados de aglomerados, e o usuário pode definir a quantidade desejada desses grupos. Não é necessário ter pixels de treinamento pré-rotulados, pois o algoritmo identifica as formações nos dados. Posteriormente, um analista atribui rótulos às classes representadas pelos aglomerados. As etapas incluem a segmentação dos dados, a classificação dos pixels nesses grupos, a criação de um mapa de classes espectrais, a rotulagem das for-

mações pelo analista e a geração de um mapa com base nos aglomerados rotulados, conforme destacado por Oliveira (2018), Ponnusamy, Sathiamoorthy e Kaliyamoorthi (2020).

Além disso, existem alguns processos que de acordo com Ponnusamy, Sathiamoorthy e Kaliyamoorthi (2020) e Gonzalez e Woods (2010), eles podem ser descritos da seguinte maneira:

- **Aquisição da imagem:** Esta é a primeira etapa na classificação de imagens. Envolve a captura ou coleta de imagens para análise. As imagens podem ser adquiridas de várias fontes, como câmeras digitais, scanners, satélites, etc. A qualidade da imagem adquirida afeta diretamente as etapas subseqüentes do processo.
- **Pré-processamento da imagem:** Após a aquisição, as imagens passam por um processo de pré-processamento para melhorar a qualidade e remover quaisquer distorções ou ruídos. Isso pode incluir etapas como correção de iluminação, normalização, equalização de histograma e filtragem.
- **Extração de características:** Esta é uma etapa importante, pois as características relevantes da imagem são extraídas para análise posterior. As características podem ser cor, textura, forma, pontos de interesse, etc. A extração eficaz de características é fundamental para a precisão do modelo de classificação.
- **Classificação de imagens:** Finalmente, as características extraídas são usadas para classificar a imagem em várias categorias. Isso é feito usando algoritmos de aprendizado de máquina ou aprendizado profundo. O algoritmo é treinado em um conjunto de dados de treinamento e, em seguida, usado para classificar novas imagens.

Oliveira (2018), ressalta que é relevante mencionar que o reconhecimento em PDI está fortemente associado às técnicas de IA, uma vez que os valores extraídos da imagem precisam ser interpretados para transformar efetivamente os dados brutos em informações significativas. Portanto, o processamento de imagem é um processo multidisciplinar que desempenha um papel fundamental em várias aplicações, desde o aprimoramento de imagens até a classificação com base em características extraídas.

2.6.3 *Deep Learning*

A classificação de imagens é uma tarefa fundamental em visão computacional, cujo objetivo é atribuir uma categoria ou rótulo pré-definido a uma imagem de entrada segundo Hwang e Sugiyama (2021). Tradicionalmente, essa tarefa era realizada em dois passos separados: extração de características e classificação. No entanto, o DL revolucionou esse processo,

integrando essas etapas em um único processo de aprendizado ponta a ponta segundo estudos de Hwang e Sugiyama (2021), Andina *et al.* (2018).

Nas abordagens tradicionais de ML, a extração de características envolve o projeto e a seleção manual de características relevantes das imagens de entrada. Essas características são então usadas como entrada para um classificador, que aprende a distinguir entre diferentes categorias com base nas características extraídas. Frequentemente, essa abordagem demanda conhecimento especializado na área e intervenção manual para a seleção e design adequado do conjunto de características como ressaltado nos estudos de Hwang e Sugiyama (2021).

Por outro lado, no aprendizado profundo é adotado uma abordagem diferente. A extração de características e a classificação são integradas de forma transparente em um único processo. Essa integração é alcançada por meio do uso de redes neurais artificiais, especificamente *Convolutional Neural Network (CNN)* no contexto da classificação de imagens. As CNN são capazes de aprender automaticamente características hierárquicas a partir dos dados brutos de pixels sem a necessidade de engenharia manual de características (HWANG; SUGIYAMA, 2021; ANDINA *et al.*, 2018).

Na Tabela 1, são mostrados importantes marcos na história das CNN e ML.

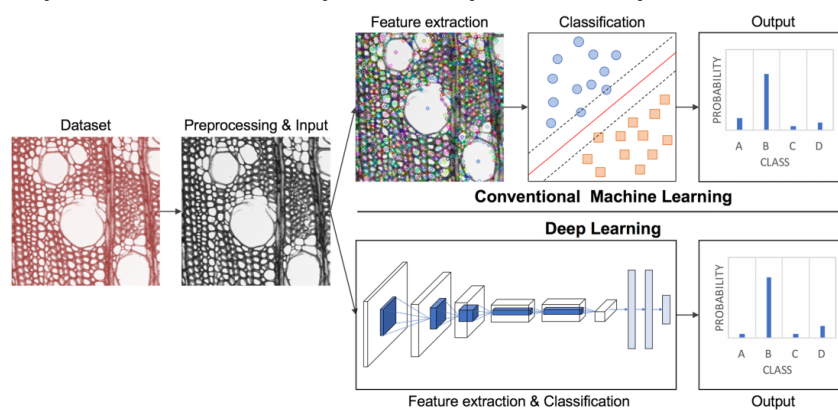
Tabela 1 – Marcos importantes na história das redes neurais e do aprendizado de máquina.

Marcos/Contribuição	Contribuidor/Ano
MCP model, considerado o ancestral da Rede Neural Artificial	McCulloch & Pitts, 1943
Regra de aprendizado Hebbiano	Hebb, 1949
Primeiro perceptron	Rosenblatt, 1958
Backpropagation	Werbos, 1974
Neocognitron, considerado o ancestral da Rede Neural Convolutiva	Fukushima, 1980
Máquina de Boltzmann	Ackley, Hinton & Sejnowski, 1985
Máquina de Boltzmann Restrita (inicialmente conhecida como Harmonium)	Smolensky, 1986
Rede Neural Recorrente	Jordan, 1986
Autoencoders	Rumelhart, Hinton & Williams, 1986
	Ballard, 1987
LeNet, marcando o início da era das Redes Neurais Convolutivas	LeCun, 1990
LSTM	Hochreiter & Schmidhuber, 1997
Rede de Crença Profunda, inaugurando a "era do aprendizado profundo"	Hinton, 2006
Máquina de Boltzmann Profunda	Salakhutdinov & Hinton, 2009
AlexNet, marcando o início da era das CNN usadas para classificação ImageNet	Krizhevsky, Sutskever, & Hinton, 2012

Fonte: Adaptado de Andina *et al.* (2018).

Como relatado no estudo de Hwang e Sugiyama (2021), o fluxo de trabalho na classificação de imagens baseada em DL geralmente começa com a aquisição de um conjunto de dados de imagens anotadas. Essas imagens são então usadas para treinar um modelo de aprendizado profundo, processo esse representado na Figura 3. Durante o treinamento, o modelo aprende automaticamente a extrair características relevantes das imagens e, ao mesmo tempo, otimizar o desempenho de classificação. A principal vantagem do DL é sua capacidade de aprender características complexas e abstratas a partir dos dados, capturando padrões complexos que podem ser difíceis de especificar manualmente.

Figura 3 – Fluxo de trabalho geral de classificação de imagens usando modelos de aprendizado de máquina convencional e aprendizado profundo, respectivamente.



Fonte: Hwang e Sugiyama (2021).

Enquanto as abordagens tradicionais de ML permitem intervenção manual na engenharia de características, o DL minimiza a necessidade desse tipo de intervenção. Isso é importante ao lidar com conjuntos de dados grandes e complexos, já que os modelos de DL podem se adaptar aos dados e descobrir representações significativas por conta própria Hwang e Sugiyama (2021).

2.7 You Only Look Once

A arquitetura *You Only Look Once* (YOLO) revolucionou o campo da visão computacional, especialmente no que diz respeito à detecção de objetos em imagens e vídeos. Ela introduziu um novo paradigma para identificar e localizar objetos de maneira rápida e precisa. Diferente de métodos tradicionais que dividem a detecção em várias etapas (como propostas de região e subsequente classificação), ela trata a tarefa como um problema de regressão único e unificado. Essa abordagem permite que a rede neural analise a imagem completa em uma única passada, resultando em uma detecção extremamente eficiente e com menor tempo de processamento, segundo a pesquisa de Redmon *et al.* (2016).

Ainda segundo o mesmo autor, a YOLO divide a imagem em uma grade e, para cada célula da grade, prevê caixas delimitadoras e probabilidades de classe. Ao integrar a detecção de objetos em um único estágio, ela oferece vantagens significativas em termos de velocidade,

tornando-a ideal para aplicações em tempo real, como vigilância de segurança, assistência à direção autônoma e análise de vídeo ao vivo.

Desde sua primeira versão, a YOLO passou por diversas melhorias, evoluindo para versões mais avançadas como YOLOv2, YOLOv3, e etc. Cada iteração trouxe avanços em precisão, capacidade de detecção em diferentes escalas e robustez contra desafios típicos da visão computacional, como oclusões e variações de iluminação, de acordo com os autores Redmon e Farhadi (2016) e Redmon e Farhadi (2018).

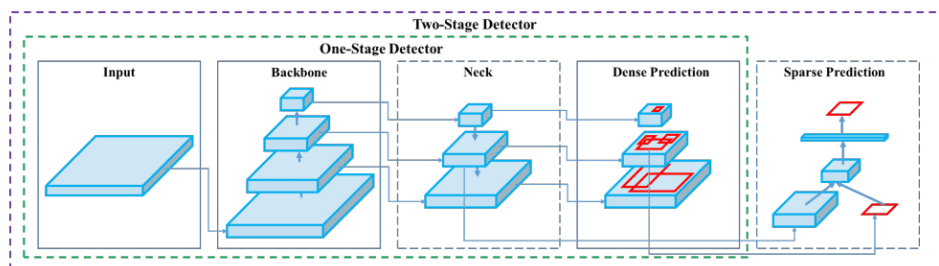
Atualmente, o YOLOv10 é a versão mais recente da série YOLO, uma arquitetura que revolucionou a detecção de objetos desde sua introdução em 2016, conforme pesquisas recentes Solimani *et al.* (2024). No entanto, o modelo utilizado neste trabalho é o YOLOv8, lançado em janeiro de 2023 pela Ultralytics.

A escolha do YOLOv8 se deve ao fato de que, quando este projeto foi iniciado, essa era a versão mais recente disponível. Além disso, novas versões do YOLO têm sido lançadas em curtos intervalos de tempo, o que torna inviável a adoção contínua de cada atualização ao longo do desenvolvimento do estudo. O YOLOv8 foi selecionado por apresentar um equilíbrio entre desempenho e eficiência computacional, além de oferecer suporte a múltiplas tarefas de visão computacional, incluindo detecção de objetos, segmentação, estimativa de pose, rastreamento e classificação Terven, Córdova-Esparza e Romero-González (2023).

Embora versões mais recentes, como o YOLOv10 e YOLOv11, possam apresentar melhorias incrementais, a adoção de um modelo consolidado e amplamente testado garante maior estabilidade e reprodutibilidade dos experimentos.

A arquitetura do YOLOv8 é composta por três componentes principais, como evidenciado em pesquisas recentes de Solimani *et al.* (2024), Terven, Córdova-Esparza e Romero-González (2023) e Hussain (2023), conforme a Figura 4:

Figura 4 – A arquitetura dos detectores de objetos modernos.



Fonte: Hussain (2023).

Cada bloco da arquitetura desempenha um papel fundamental na extração, processamento e predição das características das imagens. A seguir, cada um desses componentes será explicado detalhadamente, evidenciando sua função e implementação dentro do YOLOv8.

- **Input (Entrada da Rede):**

Função: Recebe a imagem de entrada, processando-a para garantir que esteja no formato adequado para o modelo.

YOLOv8: Redimensiona e normaliza as imagens, ajustando-as ao tamanho esperado pela rede. Além disso, técnicas de pré-processamento, como a conversão para diferentes espaços de cor e filtragem, podem ser aplicadas para otimizar a extração de características.

- **Backbone (Extrator de Características):**

Função: Extrai características significativas da entrada, capturando padrões simples e representando a entrada de forma hierárquica.

YOLOv8: Baseia-se em uma variante otimizada do *Cross Partial Stage (CSP)*, chamada C2f, inspirada na estrutura *Efficient Layer Aggregation Network (ELAN)* do YOLOv7. Essa variante reduz a complexidade computacional geral, mantendo a eficiência na extração de características. Além disso, utiliza o módulo SPPF para melhorar a detecção em diferentes escalas.

- **Neck (Ponte entre o Backbone e o Head):**

Função: Realiza a fusão de características e integra informações contextuais em diferentes escalas.

YOLOv8: Utiliza o módulo PAN-FPN, que combina informações de múltiplas escalas, permitindo capturar tanto características globais quanto detalhes específicos.

- **Head (Gerador de Saídas da Rede):**

Função: Gera as saídas finais, como caixas delimitadoras e pontuações de confiança para detecção de objetos.

YOLOv8: Adota uma arquitetura sem âncoras, que localiza objetos com base em seus centros e prevê distâncias até as bordas da caixa delimitadora. Essa abordagem aumenta a flexibilidade na detecção de objetos de diferentes tamanhos e melhora a precisão.

- **Dense Prediction (Predição Densa):**

Função: Realiza a detecção de objetos em diversas regiões da imagem com base em mapas de características densos.

YOLOv8: Gera previsões para múltiplas escalas simultaneamente, utilizando um conjunto fixo de âncoras ou abordagens adaptativas para identificar objetos com precisão.

- **Sparse Prediction (Predição Esparsa - Apenas para Two-Stage Detectors):**

Função: Refina as detecções realizadas na etapa anterior, removendo falsas previsões e melhorando a precisão da localização dos objetos.

YOLOv8: Como se trata de um One-Stage Detector, essa etapa não é aplicada diretamente, pois o modelo já realiza a classificação e localização de objetos em uma única passagem pela rede.

Além da arquitetura, diversas técnicas de aumento de dados (*Data Augmentation*) foram empregadas para aumentar a robustez e a capacidade de generalização do modelo, enriquecendo o conjunto de treinamento, como descrito em Bochkovskiy, Wang e Liao (2020), Zhang *et al.* (2018), Devries e Taylor (2017), Zhong *et al.* (2020), Krizhevsky, Sutskever e Hinton (2017) e Howard (2013):


- **Cutout Regularization:** Consiste em mascarar áreas específicas das imagens para forçar o modelo a aprender características globais, reduzindo a dependência de regiões específicas (DEVRIES; TAYLOR, 2017).
- **Random Erasing:** Introduz regiões aleatórias mascaradas, simulando oclusões e ruídos nos dados para melhorar a resiliência do modelo (ZHONG *et al.*, 2020).
- **Color Jitter:** Altera aleatoriamente características de cor das imagens, como brilho, saturação e tonalidade, simulando variações naturais de iluminação (KRIZHEVSKY; SUTSKEVER; HINTON, 2017; HOWARD, 2013).
- **Mixup:** Mistura duas imagens aleatoriamente, suavizando as fronteiras entre categorias semelhantes (BOCHKOVSKIY; WANG; LIAO, 2020).
- **Mosaic:** Combina quatro imagens diferentes em uma única amostra, expondo o modelo a variações de contexto e escala (ZHANG *et al.*, 2018).

Essas técnicas, como ilustrado na Figura 5, aumentam a diversidade do conjunto de dados e permitem que o modelo se concentre nas características visuais mais relevantes das espécies florestais, reduzindo a influência de ruídos ou padrões locais que poderiam prejudicar o desempenho.

Com a combinação de uma arquitetura otimizada e estratégias avançadas de aumento de dados, o YOLOv8 é capaz de generalizar para novos dados, mesmo em cenários adversos ou desbalanceados, contribuindo para a eficiência na identificação de espécies florestais.

A abordagem de filtragem de regiões irrelevantes, combinada com o uso de previsões (*pred*) e etiquetas reais (*labels*), desempenha um papel fundamental na melhoria do desempenho do modelo. Ao reduzir a interferência de dados não úteis, a acurácia do modelo é potencialmente ampliada, favorecendo resultados mais consistentes e confiáveis.

Figura 5 – Exemplo de Imagens de Treinamento com Regiões Irrelevantes Mascaradas.



Fonte: Autoria própria (2025).

2.7.1 Métricas de Avaliação

No contexto de modelos como o YOLOv8, a avaliação do desempenho é um aspecto crítico para garantir a eficácia em tarefas de classificação e detecção de objetos. Métricas como acurácia, precisão, recall e F1-score são amplamente utilizadas para analisar a qualidade das predições do modelo. O YOLOv8 já fornece essas métricas automaticamente durante o treinamento e a validação, utilizando ferramentas embutidas da biblioteca Ultralytics. No entanto, para análises personalizadas, essas métricas podem ser calculadas manualmente a partir da matriz de confusão usando equações conforme Developers (2024) apresentadas a seguir.

2.7.1.1 Acurácia

Segundo Siblini *et al.* (2020), a acurácia é uma métrica essencial para medir o desempenho global de modelos de classificação. Ela representa a proporção de instâncias corretamente classificadas em relação ao total de instâncias avaliadas. A equação matemática para a acurácia é:

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

No qual:

- **TP:** Verdadeiros Positivos
- **TN:** Verdadeiros Negativos
- **FP:** Falsos Positivos
- **FN:** Falsos Negativos

No entanto, Mariano (2021) alerta que, em conjuntos de dados desbalanceados, a acurácia pode ser enganosa, pois classes dominantes podem inflar os valores dessa métrica, ocultando o desempenho ruim em classes minoritárias.

2.7.1.2 Precisão e Recall

De acordo com Mariano (2021), a precisão (precision) mede a proporção de verdadeiros positivos entre todas as predições positivas, avaliando a capacidade do modelo de evitar falsos positivos. Já o recall, como destacado por Siblini *et al.* (2020), mede a proporção de verdadeiros positivos em relação ao total de instâncias da classe positiva, avaliando a habilidade do modelo em minimizar falsos negativos. Suas equações são:

$$\text{Precisão} = \frac{TP}{TP + FP} \quad (3)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (4)$$

2.7.1.3 F1-Score

O F1-score é a média harmônica entre precisão e recall, combinando essas duas métricas em um único valor. Segundo Mariano (2021), essa métrica é particularmente relevante em cenários de desbalanceamento de classes, pois oferece uma visão mais equilibrada do desempenho do modelo, considerando tanto os falsos positivos quanto os falsos negativos. Sua equação é dada por:

$$F1\text{-Score} = 2 \times \frac{\text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}} \quad (5)$$

Siblini *et al.* (2020) também reforçam a utilidade do F1-score em aplicações em que o custo de erros varia entre diferentes tipos de predições incorretas.

O YOLOv8, ao ser treinado com a biblioteca Ultralytics, exibe automaticamente as métricas de precisão, recall e F1-score na avaliação do modelo. Entretanto, para uma análise mais aprofundada, essas métricas podem ser extraídas da matriz de confusão gerada e recalculadas conforme necessário.

2.7.2 Dados de Treinamento e Validação

De acordo com Ultralytics (2024), durante o treinamento e validação do modelo YOLOv8, são empregados diversos termos para descrever os dados e previsões. Estes termos estão organizados em duas categorias principais: treinamento e validação.

Para validação, tem-se os seguintes termos:

- **valBatchX_pred**: Previsões feitas pelo modelo para o lote X de dados de validação.
- **valBatchX_labels**: Etiquetas reais associadas ao lote X de dados de validação.

Para treinamento, os termos utilizados são:

- **train_BatchX_pred**: Previsões feitas pelo modelo para o lote X de dados de treinamento.
- **train_BatchX_labels**: Etiquetas reais associadas ao lote X de dados de treinamento.

Para ilustrar melhor as diferentes combinações de características das espécies florestais, foram incluídas algumas imagens exemplificativas. Cada imagem é composta por uma seção transversal, seguida por uma seção tangencial, e uma faixa colorida que representa a característica organoléptica da dureza da madeira.

2.8 Trabalhos Relacionados

A identificação automática de espécies florestais é um campo de pesquisa em desenvolvimento, com o potencial de melhorar a forma de como são gerenciados os recursos florestais. Segundo Paula Filho (2012), a identificação de espécies florestais é frequentemente realizada por especialistas humanos, um processo que pode ser demorado, caro e sujeito a erros.

Nesse contexto, o campo do aprendizado de máquina apresenta uma abordagem promissora para automatizar essa tarefa, oferecendo a perspectiva de aprimorar a acurácia, a eficiência e a acessibilidade da identificação das espécies florestais. A seguir, são explorados uma série de artigos, organizados cronologicamente, que tratam da identificação de espécies arbóreas.

Em Paula Filho (2012) é proposta uma abordagem baseada em fusão de características para identificação automática de espécies florestais. As imagens são divididas em sub-imagens, e suas informações de cor e textura são extraídas para criar conjuntos de treinamento, teste e validação. Os resultados são combinados por meio de fusão em duas camadas (baixa e alta) para obter a classificação final. Foram criados e usados dois bancos de dados: um de ambiente controlado e outro de campo. Diversas técnicas, como análise de cores, *Gray Level Co-occurrence Matriz (GLCM)*, histograma de borda, fractais, *Local Binary Patterns (LBP)*, *Local Phase Quantization (LPQ)* e Gabor, foram empregadas para extrair características. Os resultados incluem uma taxa de reconhecimento inicial de 95,82% para a abordagem de campo e 99,49% após a aplicação do modelo de abordagem laboratorial.

No estudo conduzido por Oliveira (2018), são comparadas técnicas tradicionais e CNN para classificação automática de espécies florestais. Foram criados três modelos distintos: reconhecimento de escala, espécies por imagens macroscópicas e microscópicas. Todos os modelos foram treinados com CNN. Dois conjuntos de dados originais foram usados: imagens macroscópicas de 10 espécies e imagens microscópicas de 5 espécies. Os melhores modelos alcançaram taxas de reconhecimento de: 100% para base de escala, 98,73% para macroscópicas e 99,11% para microscópicas, superando pesquisas anteriores. Um software web foi desenvolvido como produto final, integrando os três principais modelos.

Figueroa-Mata *et al.* (2018), desenvolveram uma rede neural convolucional profunda para identificar espécies florestais por meio de imagens de cortes de madeira. Utilizando a base de dados fornecida pela Universidade Federal do Paraná (UFPR), contendo 2.942 imagens de 41 espécies brasileiras catalogadas pelo Laboratório de Anatomia da Madeira, foram empregados os modelos LeNet e ResNet-50. Os resultados mostraram uma precisão top-1 de 93,6% com LeNet e 98,03% com ResNet-50.

Em outro estudo, realizado por Neethu e Syla (2021), foi desenvolvido um sistema automatizado para detectar espécies de madeira usando visão computacional. Recorrendo a técnicas estatísticas como LBP e GLCM, recursos foram extraídos de imagens de madeira e combinados para treinar um classificador Multi-SVM, resultando em alta precisão de classificação

(97,2%). Um novo conjunto de dados foi criado, incluindo três espécies predominantes na Índia, totalizando 1026 imagens. Com passos que envolveram pré-processamento, extração de características e classificação, o sistema superou abordagens isoladas de LBP e GLCM, demonstrando eficácia notável na identificação das espécies de madeira.

Wang e Zhao (2021), desenvolveram um método para identificação de espécies de madeira, combinando características espectrais e de textura de seções transversais obtidas por câmera e espectrômetro. Usando a base de dados FPL Wood, com imagens e espectros de 50 espécies, as características foram extraídas via métodos fractal e binário local. A fusão ocorreu pela análise de correlação canônica e a classificação usou máquinas de vetores de suporte. Resultados mostraram 99,16% de precisão na validação "deixar um de fora", superando características individuais (textura: 91,96%, espectrais: 92,67%). O método demonstrou robustez ao ruído.

Em um estudo investigativo realizado por Wu *et al.* (2021), foram utilizadas CNN para identificar madeira serrada. Um banco de dados com 3.158 imagens de 11 espécies de madeira foi utilizado para treinar três arquiteturas de CNN: *50-layer convolutional neural network* (ResNet-50), DenseNet-121 e MobileNet-V2. Essas arquiteturas foram aplicadas ao scanner Microtec Goldeneye 300 Multi-Sensor Quality Scanner™, que adquiriu imagens longitudinais de forma não destrutiva, medindo as propriedades físicas da madeira. As CNN mostraram alta precisão na identificação da madeira, com resultados acima de 95% de taxa bem-sucedida para um modelo único e até 98,2% de precisão ao combinar modelos, sendo o ResNet-50 o mais eficaz.

Kırbaş e Çifci (2022), conduziram um estudo de classificação de espécies de madeira usando CNN, avaliando quatro arquiteturas de CNN: ResNet-50, *Inception V3*, *Xception* e VGG19 com aprendizado por transferência. O conjunto de dados *WOOD-AUTH* foi empregado, contendo imagens de 12 espécies de madeira em três tipos de seções. Resultados indicam que o *Xception* teve melhor desempenho, atingindo uma precisão de classificação de 95,88% no conjunto de dados *WOOD-AUTH*.

No estudo realizado por Kai *et al.* (2022), foi desenvolvido uma metodologia utilizando a arquitetura de rede neural ResNet-50 para a classificação de espécies florestais. A transferência de aprendizado foi aplicada com camadas pré-treinadas. As imagens foram redimensionadas de macroscópicas para microscópicas, aumentando o conjunto de dados. O treinamento ocorreu no Google Colab, com diversas bibliotecas para processamento de imagens e aprendizado de máquina. As imagens utilizadas foram de blocos de madeira da Universidade Federal do Paraná. A aquisição envolveu um ambiente controlado e a câmera SONY DSC T20. A precisão do modelo, avaliada com base na precisão e erro, alcançou 100% para imagens microscópicas e entre 93,94% a 99,12% para macroscópicas. A metodologia revelou-se eficaz para identificação e classificação de espécies florestais via aprendizado profundo.

Geus *et al.* (2020), introduziu o maior conjunto de dados de imagens de microscópio de madeira até a data, com 281 espécies, tendo três tipos de seções de madeira: transversal, radial

e tangencial. A pesquisa investigou o uso de aprendizado de transferência de redes neurais profundas pré-treinadas para a classificação de espécies de madeira. Os resultados experimentais mostram que as imagens da seção transversal usando uma rede densamente conectada alcançaram uma classificação correta de 98,7%, superando a taxa de 85,9% obtida com métodos de recursos pré-definidos.

A Tabela 2, resume os resultados-chave de cada estudo que foi abordado.

Tabela 2 – Comparações entre os resultados

Autor	Classificador	Método de Extração	Micro (%)	Macro (%)
Paula Filho (2012)	SVM	Análise de cores, GLCM, histograma de borda, fractais, LBP, LPQ e Gabor	-	95,82%
Oliveira (2018)	CNN	Reconhecimento e Classificação Automatizados	99,11%	98,73%
Figuroa-Mata <i>et al.</i> (2018)	CNN	LeNet e ResNet-50	-	98,03%
Geus <i>et al.</i> (2020)	CNN	LBP e LPQ	98,7%	-
Neethu e Sylva (2021)	SVM	LBP e GLCM	97,2%	-
Wang e Zhao (2021)	SVM	Fusão de recursos espectrais e recursos de textura	-	99,16%
Wu <i>et al.</i> (2021)	CNN	Extração automatizada por meio de arquiteturas CNN	-	98,2%
Kırbaş e Çifci (2022)	CNN	DL baseada em aprendizagem profunda	-	95,88%
Kai <i>et al.</i> (2022)	CNN	ResNet-50	99,43%	99,12%

Fonte: Autoria própria (2025).

Nota-se que as CNN, em particular, têm se mostrado particularmente eficazes nesta tarefa. Os avanços recentes na área incluem o desenvolvimento de novas arquiteturas de CNN, o uso de transferência de aprendizado e a combinação de diferentes técnicas de processamento de imagens.

3 MATERIAIS E MÉTODOS

Neste capítulo, são apresentados os componentes empregados durante a execução do projeto, abrangendo as especificações do equipamento utilizado, o ambiente de programação, as bibliotecas de código aberto e os conjuntos de dados analisados.

3.1 Materiais

Para realizar os experimentos, foi importante selecionar ferramentas e técnicas adequadas que garantissem a execução eficiente dos testes e a criação do modelo de aprendizado profundo. Essa abordagem foi baseada em métodos tradicionais, assegurando uma condução cuidadosa e confiável.

3.1.1 Ambiente de desenvolvimento, Bibliotecas e ferramentas

A linguagem de programação *Python*¹ foi escolhida como principal ferramenta para o desenvolvimento deste projeto, devido à sua versatilidade e ao extenso conjunto de bibliotecas disponíveis para inteligência artificial, aprendizado de máquina e ciência de dados (PYTHON-BRASIL, 2023).

Para o ambiente de desenvolvimento, utilizou-se o *Google Colaboratory* (Colab)², uma plataforma interativa que permite a execução de códigos *Python* diretamente a partir do navegador, com suporte para *Graphics Processing Unit* (GPU) e *Tensor Processing Unit* (TPU), aumentando significativamente o desempenho durante o treinamento das redes neurais profundas (COLABORATORY, 2023). No plano padrão do Colab, foram utilizadas as seguintes configurações:

- **Central Processing Unit (CPU):** Dois núcleos Xeon 2,0 GHz;
- **Random Access Memory (RAM):** 12,7 GB;
- **Armazenamento em disco:** 107,7 GB;
- **GPU:** Tesla T4 com 15 GB de memória.

Além disso, um Microscópio Digital USB 1000x Zoom Câmera 2.0 MP Pro foi utilizado para capturar imagens macroscópicas de alta resolução das amostras.

O desenvolvimento de soluções de aprendizado profundo e visão computacional é cada vez mais impulsionado pela disponibilidade de bibliotecas e ferramentas poderosas. Neste contexto, é fundamental compreender as principais tecnologias que facilitam a construção de mo-

¹ <https://www.python.org/doc/>

² <https://colab.research.google.com/>

delos avançados e a análise de imagens. Neste tópico, será abordada uma das bibliotecas mais relevantes para a comunidade de aprendizado de máquina e visão computacional:

- **Ultralytics YOLO:** O YOLOv8, uma rede neural especializada em detecção de objetos em tempo real, foi escolhido por sua precisão e eficiência na análise de imagens (SOLIMANI *et al.*, 2024).

3.1.2 Conjunto de Dados


O desenvolvimento deste trabalho iniciou-se com a utilização de um *Dataset* abrangente, contendo imagens de diferentes espécies do bioma amazônico, originalmente fornecido por Meaurio e Filho (2024). A partir deste *Dataset*, foram realizadas alterações para incluir características organolépticas e melhorias nas imagens fornecidas, ampliando as informações disponíveis e possibilitando uma análise mais detalhada das espécies.

O *Dataset* é composto por 18 espécies diferentes, com 120 imagens de cada uma, totalizando 2.160 imagens. A maioria das espécies é de grande porte, típicas da flora amazônica, e foram selecionadas conforme a disponibilidade no momento da coleta, uma vez que havia poucas opções. Esse conjunto de dados foi fundamental para o treinamento de um modelo de aprendizado profundo, capaz de classificar as espécies a partir das imagens. A diversidade das espécies oferece uma ampla gama de características visuais, essenciais para o desenvolvimento de um modelo robusto.

Para garantir a qualidade do *Dataset*, as imagens foram capturadas sob condições controladas de iluminação e posicionamento, minimizando variações que poderiam afetar o desempenho do modelo. Além disso, as imagens foram pré-processadas para remover ruídos e ajustar o contraste, realçando características importantes das espécies.


As Figuras 6 e 7 apresentam amostras aleatórias do *Dataset* das 18 espécies utilizadas neste estudo, mostrando exemplos das seções tangenciais e transversais, respectivamente. Elas evidenciam a qualidade e a diversidade das imagens capturadas, destacando detalhes estruturais que são fundamentais para a identificação precisa das espécies.

Figura 6 – Amostras tangenciais do *Dataset* criado.



Fonte: Autoria própria (2025).

Figura 7 – Amostras transversais do *Dataset* criado.



Fonte: Autoria própria (2025).

Para complementar, a Tabela 3 lista as espécies analisadas, com suas respectivas descrições e quantidades de imagens, servindo como guia para identificação e consulta dos dados. Cada espécie possui um total de 240 imagens, distribuídas igualmente entre 120 imagens transversais e 120 imagens tangenciais.

Tabela 3 – Nomes das Espécies Florestais.

Número	Nome	Nome Científico	Quantidade
01	Angelim Vermelho	<i>Dinizia excelsa</i> Ducke	120
02	Castanha de Macaco	<i>Cariniana micrantha</i> Ducke	120
03	Catingueira	<i>Aspidosperma dispernum</i> Müll. Arg.	120
04	Cedro	<i>Cedrela odorata</i> L.	120
05	Cerejeira	<i>Amburana cearensis</i> (Allemão) A.C.Sm.	120
06	Cupiúba	<i>Goupia glabra</i> Aubl.	120
07	Garapa	<i>Apuleia leiocarpa</i> (Vogel) J.F. Macbr.	120
08	Imbuia	<i>Ocotea porosa</i> (Nees & Mart.) Barroso	120
09	Jacareúba	<i>Calophyllum brasiliense</i> Cambess.	120
10	Jatobá	<i>Hymenaea rubriflora</i> Ducke	120
11	Maçaranduba	<i>Manilkara elata</i> (Allemão ex Miq.) Monach.	120
12	Mogno	<i>Swietenia macrophylla</i> King	120
13	Muiracatiara	<i>Astronium lecointei</i> Ducke	120
14	Pariri	<i>Pouteria pariry</i> (Ducke) Baehni	120
15	Roxinho	<i>Peltogyne angustiflora</i> Ducke	120
16	Sucupira Preta	<i>Bowdichia nitida</i> Spruce ex Benth.	120
17	Tauari	<i>Couratari macrosperma</i> A.C. Sm.	120
18	Timbaúva	<i>Enterolobium contortisiliquum</i> (Vell.) Morong	120

Fonte: Autoria própria (2025).

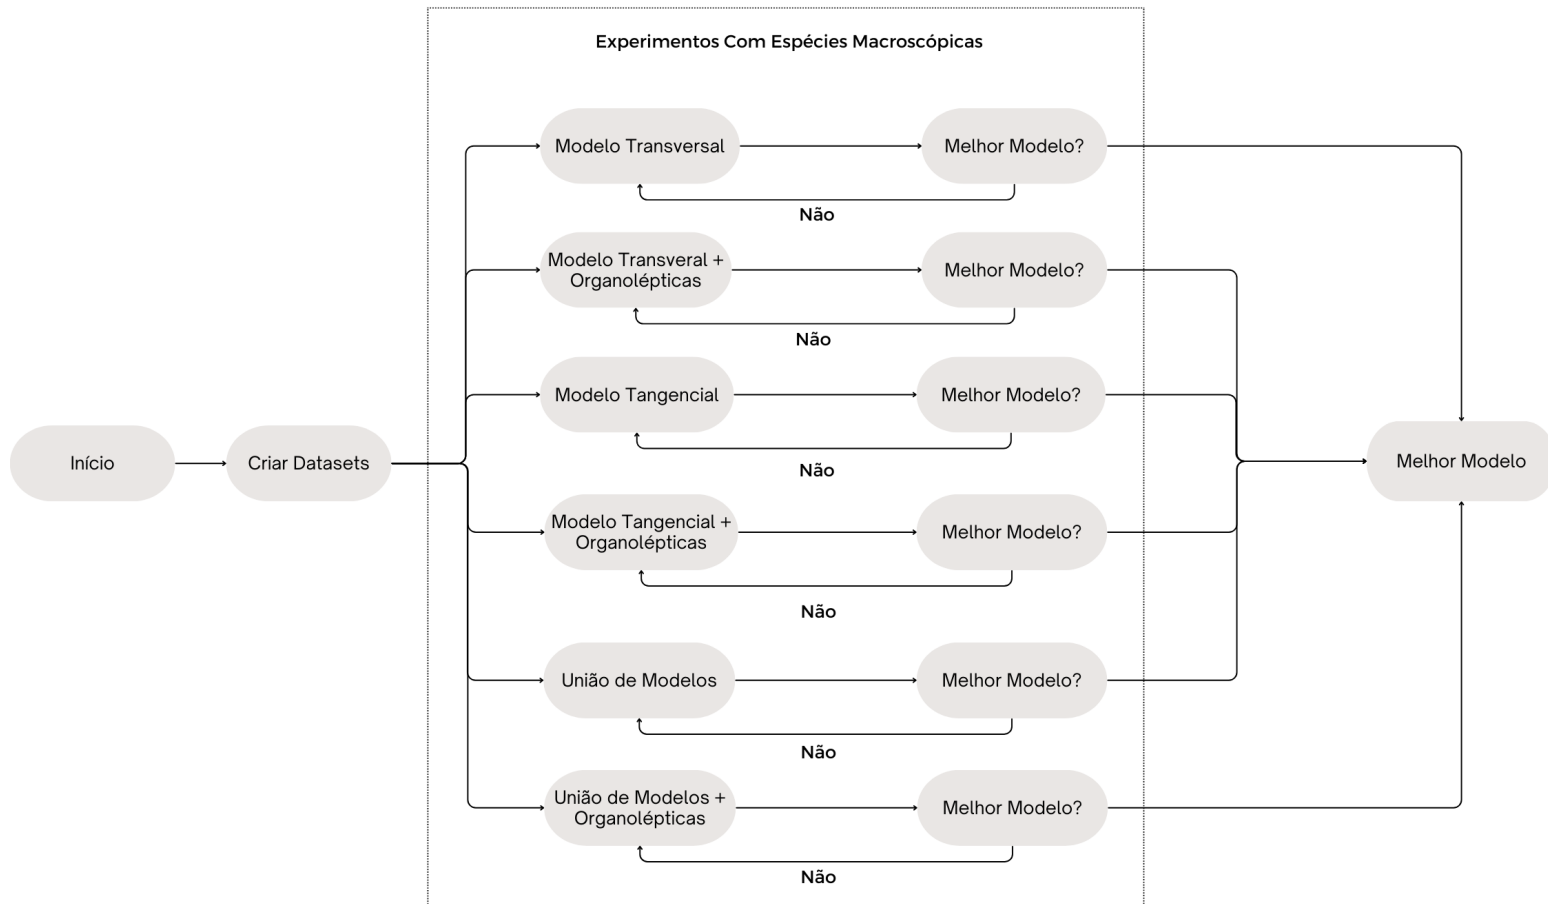
3.2 Metodologias

A partir desses conjuntos de dados, foram testadas seis combinações distintas, cada uma com uma configuração específica de imagens e características organolépticas. As combinações utilizadas nos experimentos são:

- **Combinação 1:** Conjunto de imagens transversais obtidas com um microscópio digital USB, capturando as características internas visíveis nesta perspectiva.
- **Combinação 2:** Conjunto de imagens transversais, combinado com as propriedades organolépticas de dureza de cada espécie.
- **Combinação 3:** Conjunto de imagens tangenciais capturadas com um microscópio digital USB, destacando a estrutura longitudinal da madeira.
- **Combinação 4:** Conjunto de imagens tangenciais, combinado com as propriedades organolépticas de dureza de cada espécie.
- **Combinação 5:** Conjunto que une imagens transversais e tangenciais, fornecendo uma visão conjunta das duas perspectivas.
- **Combinação 6:** Conjunto que une imagens transversais e tangenciais, além das propriedades organolépticas de dureza de cada espécie.

A Figura 8 é uma representação esquemática dos estudos propostos para espécies macroscópicas e microscópicas.

Figura 8 – Fluxograma das atividades.



Fonte: Autoria própria (2025).

3.3 Treinamento do Modelo

O treinamento do modelo foi realizado utilizando o pacote *Ultralytics YOLOv8*, implementado no ambiente *Google Colab*. O modelo YOLOv8 foi escolhido devido à sua eficiência em tarefas de detecção de objetos e classificação de imagens, características essenciais para a identificação precisa das espécies florestais do bioma amazônico.

3.3.1 Base de Dados

O *dataset* utilizado para este estudo consiste em um total de 2.160 imagens, sendo 120 imagens para cada uma das 18 espécies. O dataset foi dividido em três partes distintas: 50% das imagens (1.080 imagens) foram destinadas ao treinamento do modelo, 10% (216 imagens)

reservadas para validação, e os 40% restantes (864 imagens) alocados para o teste final. Esta proporção foi selecionada para assegurar que o modelo pudesse dispor de uma quantidade adequada de amostras para aprendizado, mantendo ao mesmo tempo um conjunto robusto para validações periódicas e uma avaliação conclusiva mais detalhada.

Para aumentar a robustez do modelo e melhorar o desempenho durante o treinamento, foi aplicada a técnica de *data augmentation* exclusivamente na base de treinamento. O *data augmentation* não foi realizado nas bases de validação e teste. O uso de 40% para testes visa garantir uma análise extensa do desempenho do modelo, refletindo sua eficácia em situações mais amplas.

3.3.2 Dureza - Método Janka

Assim, a base de dados utilizada neste estudo foi ampliada com a inclusão da dureza Janka como uma nova variável, além das imagens transversais e tangenciais já existentes. Essa característica organoléptica desempenha um papel importante na análise das espécies.

As amostras foram categorizadas com base nessa dureza, por meio de um sistema de cores conforme indicado por (BRASILEIRO, 2024; IPT, 2024): espécies com alta resistência ao corte foram identificadas com a cor vermelha, resistência média com a cor azul e madeira macia com a cor verde. A Tabela 4 apresenta todas as espécies analisadas, com suas respectivas classificações de densidade e dureza Janka, destacando as características implementadas neste estudo.

Para ilustrar melhor as diferentes combinações de características das espécies florestais, foram incluídas algumas imagens exemplificativas. Cada imagem é composta por uma seção transversal, seguida por uma seção tangencial, e uma faixa colorida que representa a característica organoléptica da dureza da madeira.


Tabela 4 – Nomes das espécies com densidade e dureza Janka

Número	Nome	Densidade(g/cm³)	Janka (N)	Dureza
01	Angelim Vermelho	0,97	14317,75	Dura
02	Castanha de Macaco	0,67	4579,72	Macia
03	Catingueira	0,80	9247,69	Dura
04	Cedro	0,49	7472,69	Macia
05	Cerejeira	0,52	5099,47	Média
06	Cupiúba	0,82	11287,48	Dura
07	Garapa	0,86	7305,97	Dura
08	Imbuia	0,65	4276	Dura
09	Jacareúba	0,62	7864,95	Dura
10	Jatobá	0,85	12287,76	Dura
11	Maçaranduba	0,96	8698,52	Dura
12	Mogno	0,56	5070,05	Macia
13	Muiracatiara	0,90	8737,75	Dura
14	Pariri	0,92	4315	Dura
15	Roxinho	0,91	12768,29	Dura
16	Sucupira Preta	0,99	14847,31	Dura
17	Tuari	0,67	4579,72	Macia
18	Timbaúva	0,40	3854,02	Macia

Fonte: Autoria própria (2025).

A seguir, na Figura 9, observam-se três espécies de madeira: Roxinho, Tauari e Cerejeira. Essas imagens exemplificam a combinação de características do modelo híbrido com informações organolépticas. A análise dessas características possibilita uma identificação mais precisa das espécies, auxiliando na classificação visual e na avaliação anatômica da madeira.

Figura 9 – Modelos Híbridos com Característica Organoléptica.



Fonte: Autoria própria (2025).

3.3.3 Abordagem com CNN

Segundo Zhuang *et al.* (2020), o *Transfer Learning* (TL) é uma metodologia no campo de aprendizado de máquina que visa melhorar o desempenho de modelos em novos domínios ou tarefas, mesmo quando há uma falta de dados rotulados para o novo problema.

Ainda de acordo com os mesmos autores, essa abordagem envolve a transferência de conhecimento adquirido em um domínio ou tarefa relacionada que possui dados rotulados adequados. Esse conhecimento é então aplicado para melhorar a capacidade do modelo no novo contexto, permitindo que ele se adapte e generalize mais eficazmente.

Será utilizado as redes neurais convolucionais (CNN) baseadas na arquitetura do YOLO para realizar a classificação de espécies florestais. A arquitetura é empregada para analisar atributos visuais das imagens de madeira, como textura, cor, padrões de grãos e densidade, extraíndo características específicas que auxiliam na identificação das espécies.

A análise ocorre em duas etapas principais. Na primeira etapa, as características visuais de cada segmento de imagem são extraídas e avaliadas de forma independente, permitindo a estimativa da probabilidade de que o segmento pertença a uma espécie específica. Na segunda etapa, os resultados obtidos são agregados, considerando todas as características analisadas, para produzir uma probabilidade global associada à espécie de madeira.

Essa abordagem permite uma análise robusta e adaptativa, integrando informações relevantes para garantir maior precisão na classificação. O uso de CNN e YOLO possibilita um processamento eficiente, contribuindo para o combate ao transporte ilegal de madeira e promovendo a sustentabilidade ambiental.

3.3.4 Parâmetros de Avaliação

- **Epoch:** O número de épocas refere-se ao número de vezes que o algoritmo de aprendizado passa por todo o conjunto de dados de treinamento. Cada época permite que o modelo ajuste seus pesos com base nos erros cometidos na época anterior, melhorando gradualmente seu desempenho. Um maior número de épocas pode levar a um melhor ajuste do modelo, mas também aumenta o risco de *overfitting* se o modelo começar a memorizar os dados de treinamento em vez de generalizar a partir deles (ULTRALYTICS, 2024).
- **Time:** O tempo de treinamento é uma medida de quanto tempo o modelo leva para completar uma época. Monitorar o tempo é importante para avaliar a eficiência do treinamento e identificar possíveis gargalos no processo. Tempos de treinamento excessivamente longos podem indicar a necessidade de otimizações no código ou no hardware utilizado (ULTRALYTICS, 2024).

- **Train/Loss:** A perda de treinamento (*train/loss*) indica o quão bem o modelo está se ajustando aos dados de treinamento. A perda é uma função que mede a diferença entre as previsões do modelo e os valores reais. Uma perda menor geralmente indica um melhor ajuste do modelo aos dados de treinamento, mas é importante monitorar para evitar *overfitting*, em que o modelo se ajusta tão bem aos dados de treinamento que perde a capacidade de generalizar para novos dados (ULTRALYTICS, 2024).
- **Metrics/Accuracy_Top1:** A acurácia *Top-1* mede a proporção de vezes que a predição mais provável do modelo é correta. É uma métrica comum em tarefas de classificação, na qual se espera que o modelo identifique corretamente a classe mais provável. Esta métrica é particularmente útil em problemas em que é essencial que a primeira predição do modelo seja a correta (ULTRALYTICS, 2024).
- **Metrics/Accuracy_Top5:** A acurácia *Top-5* mede a proporção de vezes que a classe correta está entre as cinco previsões mais prováveis do modelo. Esta métrica é útil em cenários na qual múltiplas classes podem ser relevantes e uma única predição correta pode não ser suficiente. Por exemplo, em tarefas de reconhecimento de imagem, pode ser aceitável que a classe correta esteja entre as cinco principais previsões do modelo (ULTRALYTICS, 2024).
- **Val/Loss:** A perda de validação (*val/loss*) é similar à perda de treinamento, mas é calculada usando o conjunto de validação. Monitorar a perda de validação ajuda a avaliar a capacidade de generalização do modelo e a detectar *overfitting*. Uma perda de validação que começa a aumentar enquanto a perda de treinamento continua a diminuir é um sinal de que o modelo pode estar se ajustando demais aos dados de treinamento (ULTRALYTICS, 2024).
- **Learning Rate (lr/pg0, lr/pg1, lr/pg2):** A taxa de aprendizado (*learning rate*) controla o tamanho dos ajustes que o modelo faz em seus pesos durante o treinamento. Diferentes taxas de aprendizado podem ser aplicadas a diferentes grupos de parâmetros (*pg0*, *pg1*, *pg2*) para otimizar o processo de treinamento. A taxa de aprendizado é um hiperparâmetro fundamental que determina o tamanho do passo em cada iteração ao mover-se em direção a um mínimo da função de perda. Ajustar corretamente a taxa de aprendizado é fundamental para garantir que o modelo converja de forma eficiente e eficaz, evitando tanto a subotimização quanto a oscilação em torno do mínimo (ULTRALYTICS, 2024).

4 RESULTADOS E DISCUSSÃO

Os experimentos deste trabalho foram projetados para avaliar o desempenho do modelo YOLOv8 em diferentes combinações de dados e configurações de treinamento. Antes do treinamento completo, uma série de testes preliminares foi conduzida para ajustar os parâmetros e verificar a adequação do conjunto de dados ao objetivo proposto.

Os resultados dessas etapas experimentais foram essenciais para guiar o processo de treinamento descrito na seção seguinte, permitindo ajustar o modelo YOLOv8 às peculiaridades dos dados relacionados ao Bioma Amazônico.

Para o treinamento do modelo, foram realizadas 150 épocas utilizando o YOLOv8 pré-treinado, ajustado para as necessidades deste estudo. A configuração incluiu o uso de *dropout* com uma probabilidade de 0,1 para mitigar o *overfitting*. Além disso, foram aplicadas técnicas de *data augmentation*, como *mixup* e *mosaic*, com valores de 0,1 e 0,3, respectivamente. Todas as análises realizadas utilizaram esses mesmos parâmetros, aumentando a diversidade do conjunto de dados e melhorando a capacidade de generalização do modelo.

Durante o treinamento, o desempenho foi monitorado com um conjunto de validação. Para avaliar a eficácia do modelo, foram utilizadas quatro métricas principais: acurácia, precisão, *recall* e *F1-score*. Essas métricas foram escolhidas devido à sua relevância em tarefas de classificação, como destacado por Mariano (2021) e Siblini *et al.* (2020), que ressaltam sua importância para medir o desempenho em sistemas baseados em aprendizado de máquina. Além disso, todas as análises foram realizadas com base na documentação disponibilizada por Ultralytics (2024).

O treinamento do modelo foi realizado na plataforma *Google Colab*, utilizando uma GPU Tesla T4, que proporcionou um desempenho eficiente no processamento das operações computacionais. Durante a execução, o tempo total de treinamento foi monitorado e registrado, permitindo a análise da eficiência computacional e a identificação de possíveis gargalos.

Ao final do treinamento, os pesos que apresentaram o melhor desempenho no conjunto de validação foram automaticamente salvos. Esses pesos foram utilizados para realizar a validação final em um conjunto de testes independente, assegurando a capacidade do modelo de generalizar adequadamente para novos dados. Essa etapa foi importante para avaliar a robustez do modelo em cenários que simulam aplicações reais.

Após o término do treinamento e validação, o modelo foi testado em um conjunto de dados previamente separado para mensurar seu desempenho em condições simuladas de uso real. Essa avaliação utilizou métricas amplamente reconhecidas para fornecer uma análise detalhada da eficácia do modelo na identificação de espécies florestais.

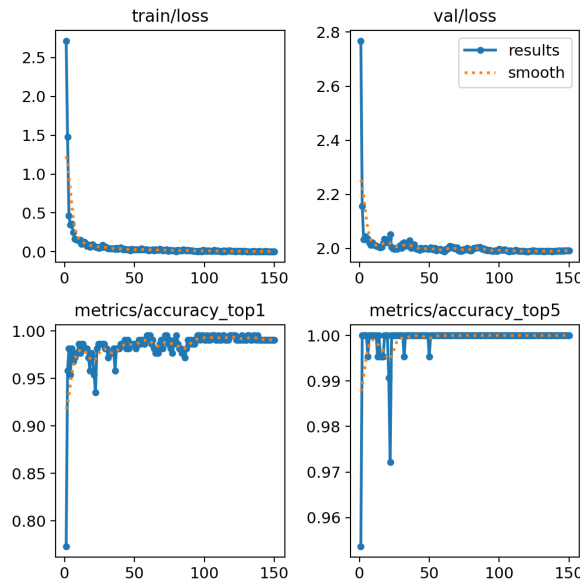
Os resultados foram organizados em tabelas que serão apresentadas a seguir, detalhando o desempenho para cada espécie incluída no conjunto de testes. Essa etapa foi essencial para validar a aplicação prática do modelo, com destaque para o uso no combate ao

desmatamento ilegal. A identificação precisa e eficiente das espécies florestais pode contribuir significativamente para a fiscalização e preservação do bioma amazônico.

4.1 Treinamento Modelo Transversal

O treinamento do modelo YOLOv8 utilizando imagens transversais do *dataset* apresentou resultados que evidenciam a eficácia do modelo. A Figura 10 ilustra o desempenho do treinamento e validação, destacando a redução contínua das perdas (*loss*) e a melhora nas métricas de precisão.

Figura 10 – Treinamento e Validação para o Modelo Transversal.




Fonte: Autoria própria (2025).

Ao longo do treinamento, métricas como *Accuracy_Top1* e *Accuracy_Top5* demonstraram a eficiência do modelo na tarefa de classificação, atingindo valores de 99% e 100%, respectivamente, nas últimas épocas. O ajuste progressivo das taxas de aprendizado também contribuiu para a convergência estável do modelo, evitando problemas como *overfitting*.

A matriz de confusão, apresentada na Figura 11, revela o alto desempenho do modelo, com apenas uma classificação incorreta entre as classes "Pariri" e "Maçaranduba". Este resultado reforça a robustez do modelo em identificar características relevantes mesmo em condições adversas. Esses resultados mostram que o modelo é eficaz para a identificação de espécies florestais, com potencial para aplicações práticas na classificação de madeiras.

Figura 11 – Matriz de Confusão para o Modelo Transversal.



Fonte: Autoria própria (2025).

4.2 Desempenho do Modelo Transversal

O modelo Transversal foi avaliado utilizando imagens de teste para todas as classes incluídas no treinamento. Para testes do modelo, todas as imagens nunca foram vistas pelo modelo de testes. A Tabela 5 apresenta o resumo das predições realizadas, destacando a média das probabilidades previstas para cada classe e a quantidade de imagens processadas.

Tabela 5 – Resumo das Predições e Imagens Processadas para o Modelo Transversal.


Classe	Média da Probabilidade	Imagens Processadas
Cerejeira	0,99999	48
Imbuia	0,99997	48
Roxinho	0,99997	48
Castanha-de-Macaco	0,99996	48
Muiracatiara	0,99992	48
Mogno	0,99989	48
Catingueira	0,99988	48
Sucupira-preta	0,99986	48
Cedro	0,99985	48
Cupiúba	0,99977	48
Jatobá	0,99962	48
Timbaúva	0,99946	48
Angelim-vermelho	0,99928	48
Jacareúba	0,99820	48
Garapa	0,99805	48
Tauari	0,99552	48
Pariri	0,98767	48
Maçaranduba	0,97831	48

Fonte: Autoria própria (2025).

Observa-se que as classes *Cerejeira*, *Imbuia* e *Roxinho* obtiveram as maiores médias de probabilidade, com valores superiores a 0,9999, indicando uma elevada confiança do modelo na classificação dessas categorias. Por outro lado, as classes *Pariri* e *Maçaranduba* apresentaram as menores médias, respectivamente 0,98767 e 0,97831, o que sugere uma menor confiança nessas predições.

Apesar das variações nas médias, todas as classes apresentaram altos níveis de probabilidade média, o que reflete a eficácia do modelo em generalizar o aprendizado para novos dados. Além disso, foi garantida uma uniformidade no número de imagens testadas, com 48 amostras por classe, assegurando a consistência dos resultados apresentados.

A Figura 12 apresenta a matriz de confusão do modelo transversal. A matriz não normalizada reforça a consistência dos resultados, evidenciando que o modelo classificou corretamente 48 imagens para a maioria das classes. Notou-se apenas um pequeno desvio na classe *Maçaranduba*, com uma imagem classificada incorretamente, conforme indicado na matriz não normalizada. Esse resultado reforça a robustez do modelo em tarefas de classificação de espécies florestais.



Fonte: Autoria própria (2025).

Na Figura 13, é possível observar um único erro de previsão do modelo, que confundiu a espécie *Maçaranduba* com *Castanha de Macaco*. O modelo atribuiu uma probabilidade de 99% para a *Castanha de Macaco* e apenas 1% para *Maçaranduba*. Na Figura 14 são apresentadas


duas amostras da espécie castanha de Macaco, comparando com a imagem da Figura 13 é possível perceber a semelhança entre as espécies.

Figura 13 – Espécie Maçaranduba confundida com Castanha de Macaco.



Fonte: Autoria própria (2025).

Figura 14 – Espécie Castanha de Macaco.




Fonte: Autoria própria (2025).

4.3 Treinamento Modelo Tangencial

Neste tópic, são apresentados os resultados do treinamento do modelo YOLOv8 utilizando imagens tangenciais do *dataset*. A Figura 15 ilustra o desempenho do modelo ao longo do treinamento e validação, destacando a redução das perdas (*loss*) e o aumento das métricas de precisão.


Além disso, a análise da matriz de confusão, apresentada na Figura 16, demonstra que o modelo alcançou um alto nível de precisão, classificando corretamente todas as amostras.

Figura 15 – Treinamento e Validação para o Modelo Tangencial.



Fonte: Autoria própria (2025).

Figura 16 – Matriz de Confusão para o Modelo Tangencial.



Fonte: Autoria própria (2025).

4.4 Desempenho do Modelo Tangencial

O modelo tangencial foi avaliado utilizando imagens de teste para todas as classes incluídas no treinamento. A Tabela 6 apresenta um resumo das predições realizadas, destacando a média das probabilidades previstas para cada classe e a quantidade de imagens processadas.

Tabela 6 – Resumo das Predições e Imagens Processadas para o Modelo Tangencial.

Classe	Média da Probabilidade	Imagens Processadas
Mogno	1,00000	48
Imbuia	0,99998	48
Castanha-de-Macaco	0,99997	48
Cedro	0,99995	48
Muiracatiara	0,99992	48
Sucupira-preta	0,99991	48
Tauari	0,99989	48
Jatobá	0,99960	48
Cerejeira	0,99956	48
Catingueira	0,99950	48
Jacareúba	0,99894	48
Timbaúva	0,99781	48
Roxinho	0,99353	48
Pariri	0,99115	48
Angelim-vermelho	0,98135	48
Maçaranduba	0,97754	48
Cupiuba	0,97049	48
Garapa	0,95665	48

Fonte: Autoria própria (2025).

O modelo tangencial apresentou uma elevada precisão na classificação de várias classes, com destaque para Mogno, Imbuia e Castanha-de-Macaco, que alcançaram médias de probabilidade próximas ou iguais a 1. Isso indica uma extrema confiança do modelo na identificação dessas categorias, sugerindo que as características dessas classes são bem representadas nos dados de treinamento.


Por outro lado, Garapa e Cupiúba demonstraram as menores médias de probabilidade, 0,95665 e 0,97049, respectivamente. Esses valores, embora ainda elevados, podem indicar maior complexidade ou variabilidade nas características dessas espécies, o que pode ter influenciado na menor confiança do modelo.

Ao observar o desempenho global, percebe-se que todas as classes apresentaram probabilidades médias superiores a 0,95, o que é um indicativo de um bom ajuste do modelo e uma forte capacidade de generalização para os dados de teste. Essa uniformidade também é reforçada pelo número constante de imagens avaliadas por classe (48), garantindo consistência na análise e confiabilidade nos resultados.

A Figura 17, apresenta a matriz de confusão não normalizada para o modelo tangencial. Os valores na diagonal principal destacam a alta taxa de acertos para todas as classes,

com exceções mínimas nas classes Garapa e Maçaranduba, que apresentaram uma pequena proporção de erros.

Figura 17 – Matriz de confusão não normalizada




Fonte: Autoria própria (2025).

Os erros de previsão do modelo evidenciam a confusão entre as espécies Maçaranduba e Garapa com Angelim Vermelho. As imagens das espécies erroneamente classificadas estão apresentadas nas Figuras 18 e 19.

Para a espécie Maçaranduba Figura 18, o modelo atribuiu 89% de probabilidade para Angelim Vermelho e apenas 11% para Maçaranduba. A Figura 20 ilustra a imagem da espécie Angelim Vermelho utilizada na predição, percebe-se que são bem próximas.

Já para a espécie Garapa, o modelo classificou 60% como Angelim Vermelho, 19% como Garapa e 17% como Mogno. A Figura 21a apresenta a imagem de Angelim Vermelho e 21b exibe a classe Mogno considerada pelo modelo.

Figura 18 – Espécie Maçaranduba confundida com Angelim Vermelho.




Fonte: A autoria própria (2025).

Figura 19 – Espécie Garapa confundida com outras Espécies.




Fonte: A autoria própria (2025).

Figura 20 – Espécie Angelim Vermelho.



Fonte: Autoria própria (2025).

Figura 21 – Espécie Angelim Vermelho e Mogno.



Fonte: Autoria própria (2025).

Além disso, os valores acima da diagonal principal na matriz de confusão representam casos em que uma determinada espécie foi incorretamente classificada como outra que aparece antes na ordem da matriz. Isso indica que o modelo identificou padrões ou tonalidades semelhantes entre as espécies e atribuiu erroneamente a classe prevista a uma espécie anterior.

Esse comportamento pode ser observado nos pares de imagens a seguir, cada conjunto apresenta, à esquerda, a espécie erroneamente classificada, e, à direita, a espécie com a qual foi confundida.


- A Figura 22 foi erroneamente classificada como Figura 23, com 74% de probabilidade para Muiracatiara e 26% para Angelim Vermelho.
- A Figura 24 foi confundida com Figura 25, apresentando 96% de probabilidade para Pariri, 2% para Cupiúba e 2% para Castanha-de-Macaco.

Figura 22 – Espécie Angelim Vermelho.



Fonte: Autoria própria (2025).

Figura 23 – Espécie Muiracatiara.




Fonte: Autoria própria (2025).

Figura 24 – Espécie Cupiúba.



Fonte: Aatoria própria (2025).

Figura 25 – Espécie Pariri.



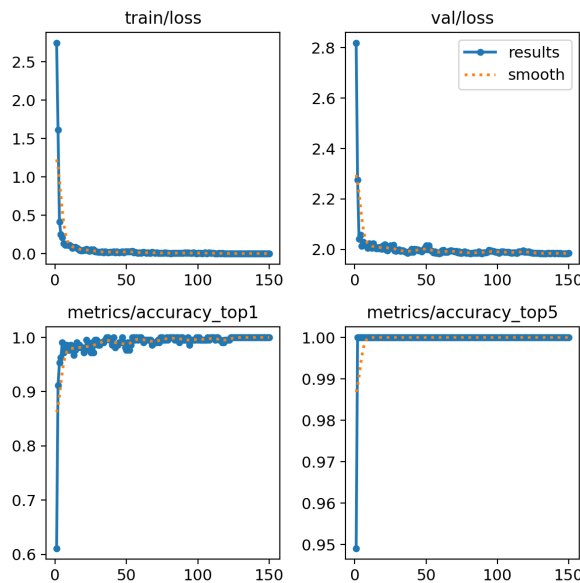
Fonte: Aatoria própria (2025).

4.5 Treinamento Modelo Híbrido

Neste estudo, foram combinadas abordagens transversais e tangenciais para avaliar o impacto da fusão de modelos na classificação de espécies florestais. O modelo combinado foi treinado utilizando imagens que integravam ambas as perspectivas microscópicas, proporcionando uma visão abrangente das características das espécies.

A Figura 26 ilustra o desempenho do modelo ao longo do treinamento e validação, destacando a redução contínua das perdas (*loss*) e o aumento das métricas de precisão.


Figura 26 – Treinamento e Validação para o Modelo Híbrido.



Fonte: Autoria própria (2025).

Os resultados da matriz de confusão normalizada, Figura 27 demonstram a eficácia do modelo híbrido, que obteve precisão de 100% em todas as classes analisadas. Esse desempenho reforça o potencial da combinação das abordagens para melhorar a classificação.

Figura 27 – Matriz de Confusão Normalizada para o Modelo Híbrido.



Fonte: Autoria própria (2025).

A fusão das perspectivas microscópicas transversal e tangencial revelou-se eficiente, integrando características complementares que melhoram a capacidade do modelo em classificar espécies florestais com alta precisão.

4.6 Desempenho do Modelo Híbrido

O modelo híbrido foi avaliado utilizando imagens de todas as classes incluídas no treinamento. A Tabela 7 apresenta um resumo das predições, destacando a média das probabilidades de acerto para cada classe e a quantidade de imagens avaliadas.

Ao analisar os resultados, nota-se que as classes *Castanha-de-Macaco*, *Muiracatiara*, *Imbuia* e *Cedro* apresentaram médias de probabilidade excepcionalmente altas, todas superiores a 0,9999, demonstrando um desempenho notável do modelo na identificação dessas espécies e uma elevada confiança nas predições.

Por outro lado, as classes *Angelim-vermelho* e *Pariri* obtiveram médias de probabilidade ligeiramente menores, com valores de 0,98765 e 0,98450, respectivamente. Embora ainda apresentem probabilidades elevadas, esses resultados indicam uma maior dificuldade do modelo em classificar essas espécies em comparação com as demais.

Tabela 7 – Resumo das Predições e Imagens Processadas para o Modelo Híbrido.

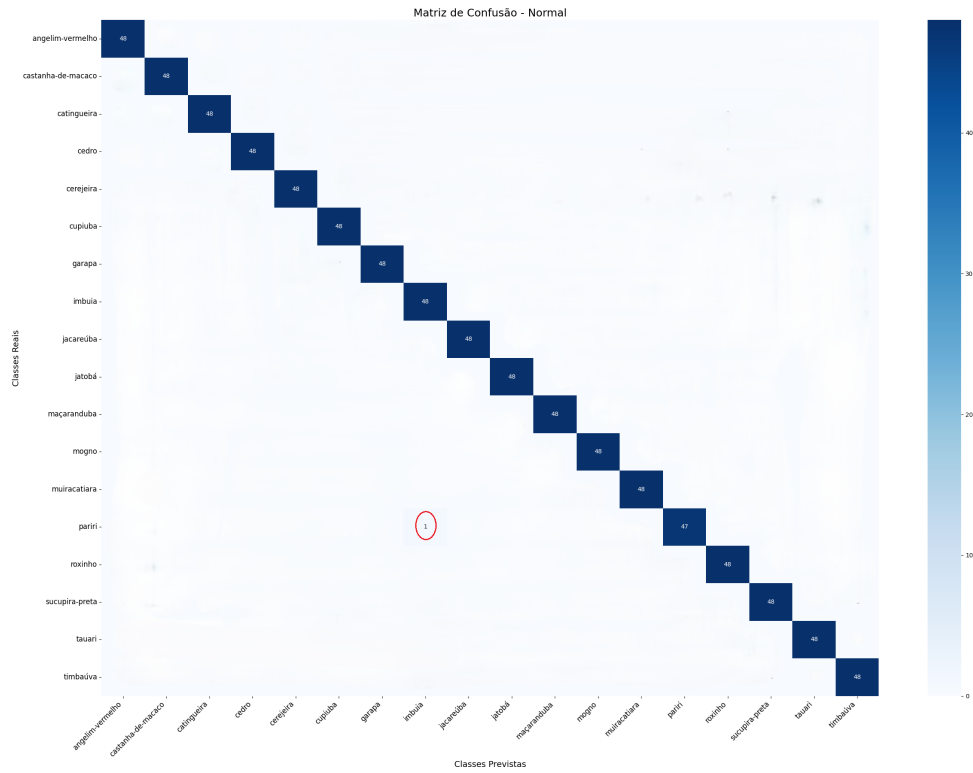
Classe	Média da Probabilidade	Imagens Processadas
Castanha-de-Macaco	1,00000	48
Muiracatiara	0,99999	48
Imbuia	0,99998	48
Cedro	0,99998	48
Sucupira-preta	0,99994	48
Jatobá	0,99986	48
Cerejeira	0,99964	48
Cupiúba	0,99957	48
Catingueira	0,99943	48
Jacareúba	0,99942	48
Mogno	0,99913	48
Tuari	0,99896	48
Garapa	0,99877	48
Maçaranduba	0,99860	48
Timbaúva	0,99825	48
Roxinho	0,99634	48
Angelim-vermelho	0,98765	48
Pariri	0,98450	48

Fonte: Autoria própria (2025).

De forma geral, o modelo mostrou uma excelente capacidade de generalização, com médias de probabilidade superiores a 0,98 para todas as 18 classes analisadas, mostrando assim a consistência dos resultados e reforçando a robustez da avaliação.

A Figura 28 apresenta a matriz de confusão não normalizada para o modelo híbrido. A matriz mostra os números absolutos de acertos e erros, destacando a alta taxa de acertos, sendo que apenas uma amostra de *Pariri* foi incorretamente classificada como Imbuia, conforme evidenciado na matriz. Esses resultados reforçam a consistência do modelo e identificam áreas potenciais para ajustes e refinamentos.


Figura 28 – Matriz de confusão



Fonte: Autoria própria (2025).

Os erros de previsão do modelo podem ser observados, com a confusão da espécie Pariri com Imbuia e Cedro. A imagem da espécie confundida é mostrada na Figura 29. O modelo atribuiu uma probabilidade de 53% para Imbuia, para Pariri 28% e 14% para Cedro, espécie Imbuia representada na Figura 30.

Figura 29 – Espécie Híbrida.



Fonte: Autoria própria (2025).

Figura 30 – Espécie Imbuia.



Fonte: Autoria própria (2025).

O modelo híbrido apresenta um desempenho promissor, com alta confiança na maioria das classes e precisão suficiente para aplicações práticas em classificação de espécies florestais.

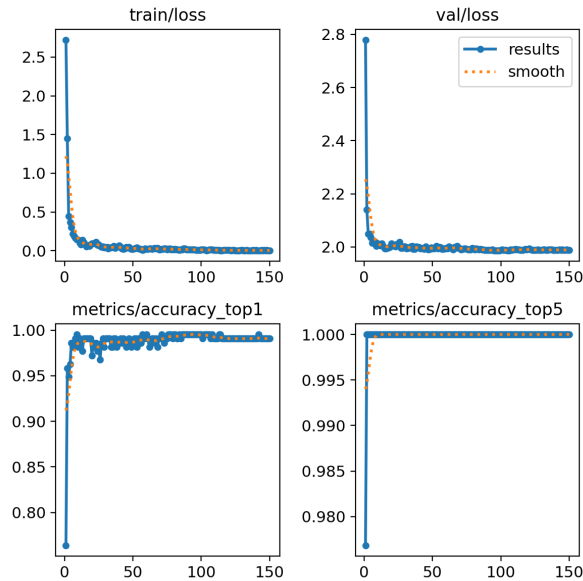
4.7 Treinamento Modelo Transversal com Características Organolépticas

O modelo transversal foi aprimorado pela inclusão de características organolépticas, como a cor, que está diretamente associada à dureza das espécies. Essa integração permitiu explorar correlações entre a textura visual e propriedades físicas, tornando a classificação mais precisa, especialmente para espécies com estruturas visuais semelhantes.

A Figura 31 ilustra o desempenho do modelo ao longo do treinamento e validação, demonstrando uma significativa redução das perdas (*loss*) e melhora na estabilidade das métricas de aprendizado.


A matriz de confusão apresentada na Figura 32 ilustra o desempenho do modelo na classificação de espécies utilizando imagens transversais com características organolépticas. O modelo apresentou alta precisão para a maioria das classes, com valores corretos predominando na diagonal principal.

Figura 31 – Treinamento e Validação para o Modelo Transversal com Características Organolépticas.



Fonte: Autoria própria (2025).

Figura 32 – Matriz de Confusão para o Modelo Transversal com Características Organolépticas.



Fonte: Autoria própria (2025).

No entanto, foi observado um pequeno erro em uma das classificações, em que a espécie *Pariri* foi confundida com outra classe em uma única instância. Essa leve discrepância é esperada em sistemas complexos e pode ser atribuída a similaridades visuais entre as classes ou variações nos dados de entrada.

Esses resultados confirmam a eficácia do modelo em capturar padrões relevantes para a classificação, ao mesmo tempo que indicam oportunidades de ajuste fino para melhorar a acurácia em casos específicos.

4.8 Desempenho do Modelo Transversal com Características Organolépticas

O modelo foi avaliado utilizando imagens de todas as classes contempladas no processo de treinamento. A Tabela 8 apresenta um panorama das predições, incluindo a média das probabilidades de acerto por classe e o total de imagens analisadas.

A análise dos resultados revela que as classes Cerejeira, Mogno, Imbuia e Cupiúba alcançaram médias de probabilidade extremamente altas, todas superiores a 0,9999, indicando uma performance excepcional do modelo na identificação dessas espécies, com elevada precisão nas predições realizadas.

Por outro lado, as classes Angelim-vermelho e Pariri apresentaram médias de probabilidade mais baixas, com valores de 0,99709 e 0,97414, respectivamente. Embora essas probabilidades ainda sejam altas, refletem uma maior complexidade do modelo em classificar essas espécies, possivelmente devido a características mais sutis ou menos evidentes em comparação com outras classes.

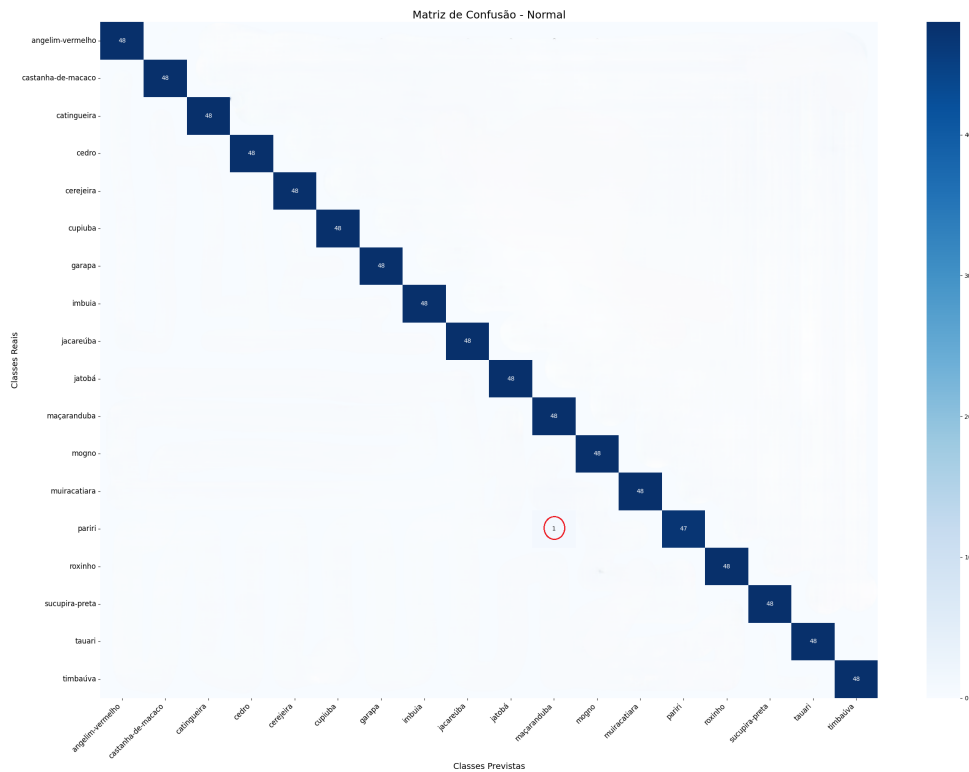
Tabela 8 – Resumo das Predições e Imagens Processadas para o Modelo Transversal com características organolépticas.

Classe	Média da Probabilidade	Imagens Processadas
Cerejeira	1,00000	48
Mogno	0,99999	48
Imbuia	0,99999	48
Cupiúba	0,99998	48
Catingueira	0,99994	48
Tuari	0,99994	48
Cedro	0,99990	48
Timbaúva	0,99989	48
Roxinho	0,99987	48
Sucupira-preta	0,99981	48
Muiracatiara	0,99977	48
Jacareúba	0,99931	48
Jatobá	0,99883	48
Angelim-vermelho	0,99709	48
Maçaranduba	0,99483	48
Garapa	0,99460	48
Castanha-de-Macaco	0,99436	48
Pariri	0,97414	48

Fonte: Autoria própria (2025).

No geral, o modelo demonstrou excelente capacidade de generalização, com médias de probabilidade superiores a 0,97 para todas as classes avaliadas. A consistência no número de imagens processadas (48 por classe) reforça a confiabilidade da análise e atesta a robustez dos resultados obtidos.

Figura 33 – Espécie Híbrida Pariri confundida com Maçaranduba.



Fonte: Autoria própria (2025).


O modelo apresentou uma inconsistência ao classificar a espécie Pariri, atribuindo erroneamente uma alta probabilidade de 98% para Maçaranduba e apenas 2% para Pariri. Esse resultado sugere que o modelo encontrou dificuldades em diferenciar essas duas espécies, possivelmente devido a semelhanças na textura, nos padrões anatômicos ou na tonalidade da madeira. A Figura 34 ilustra a amostra que levou a essa classificação incorreta, enquanto a Figura 40 apresenta uma amostra real de Maçaranduba.

Figura 34 – Espécie Pariri classificada erroneamente como Maçaranduba.



Fonte: Aatoria própria (2025).

Figura 35 – Espécie Maçaranduba.



Fonte: Aatoria própria (2025).

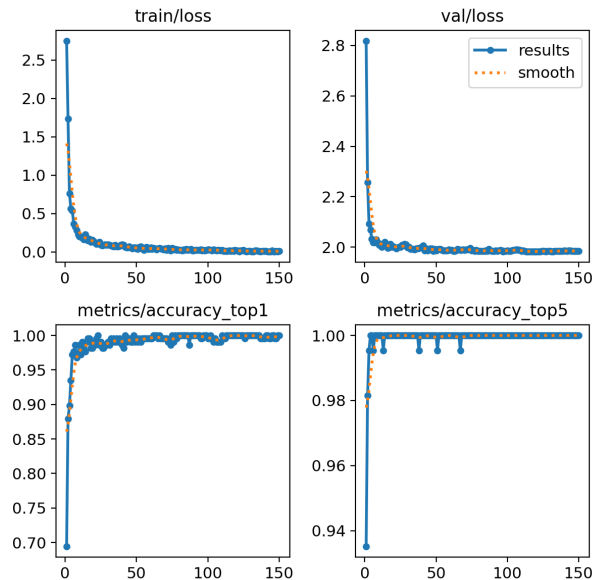
4.9 Treinamento Modelo Tangencial com Características Organolépticas

O modelo tangencial foi aprimorado pela inclusão de características organolépticas, como a cor, diretamente associada à dureza das espécies. Essa abordagem permitiu ao mo-

delo identificar correlações entre propriedades visuais e físicas, resultando em maior precisão na classificação.

Durante o treinamento, observou-se uma redução significativa do erro (*train/loss*), como demonstrado na Figura 36. O modelo apresentou alta capacidade de generalização, com perdas estáveis nos dados de validação e resultados consistentes nas métricas de precisão.


Figura 36 – Matriz de Confusão para o Modelo Tangencial com Características Organolépticas.



Fonte: Autoria própria (2025).

A matriz de confusão, apresentada na Figura 37, evidencia o desempenho do modelo em classificar corretamente a maioria das espécies. A matriz revela valores predominantes na diagonal principal, indicando alta precisão geral. Não foram observados erros ou confusões entre as classes, o que destaca a robustez do modelo em lidar com imagens tangenciais enriquecidas com dados organolépticos.

Figura 37 – Matriz de Confusão para o Modelo Tangencial com Características Organolépticas.



Fonte: Autoria própria (2025).

4.10 Desempenho do Modelo Tangencial com Características Organolépticas

O modelo Tangencial com Características Organolépticas foi avaliado utilizando imagens de todas as classes do conjunto de dados. A Tabela 9 apresenta um resumo detalhado das predições realizadas, destacando a média das probabilidades de acerto por classe e o total de imagens processadas.

Tabela 9 – Resumo das Predições e Imagens Processadas para o Modelo Tangencial com Características Organolépticas.

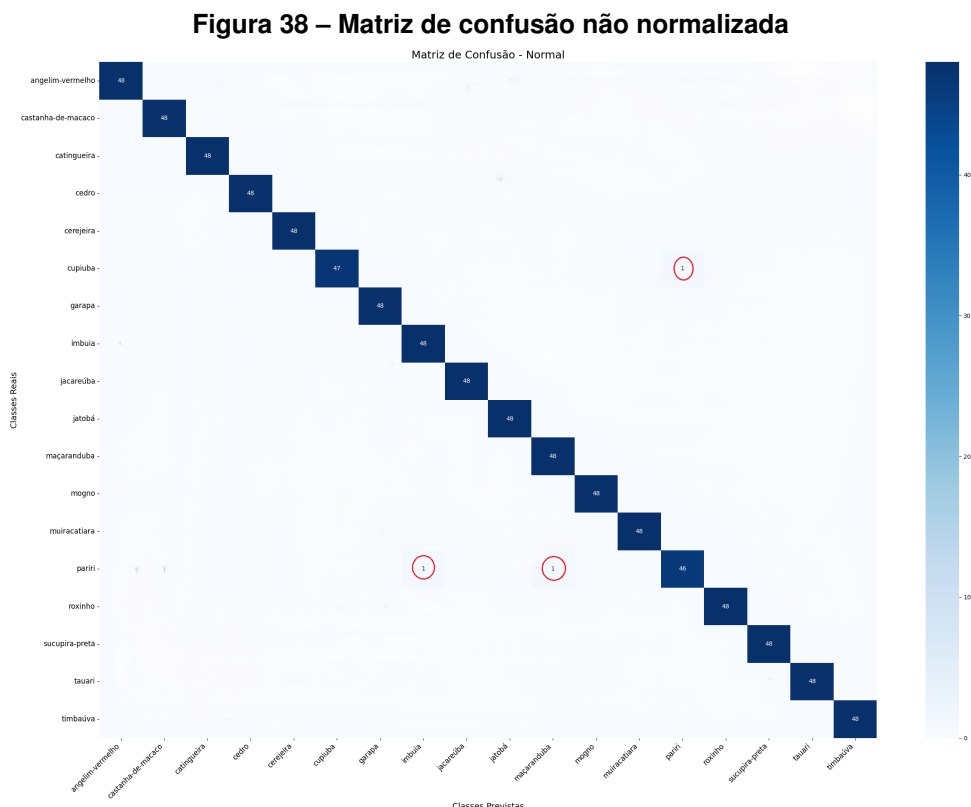
Classe	Média da Probabilidade	Imagens Processadas
Jacareúba	1,00000	48
Cedro	0,99998	48
Imbuia	0,99997	48
Cerejeira	0,99996	48
Muiracatiara	0,99993	48
Garapa	0,99978	48
Mogno	0,99971	48
Castanha-de-Macaco	0,99971	48
Timbaúva	0,99963	48
Tauari	0,99957	48
Maçaranduba	0,99956	48
Angelim-vermelho	0,99929	48
Roxinho	0,99908	48
Jatobá	0,99731	48
Catingueira	0,99575	48
Sucupira-preta	0,99077	48
Cupiúba	0,97443	48
Pariri	0,95542	48

Fonte: Autoria própria (2025).

Os resultados indicam que a classe Jacareúba obteve uma média de probabilidade perfeita (1.00000), demonstrando um desempenho excepcional do modelo na identificação dessa espécie. Classes como Cedro, Imbuia e Cerejeira também alcançaram médias superiores a 0,9999, evidenciando a alta acurácia do modelo para essas categorias.

Entretanto, algumas classes apresentaram médias de probabilidade relativamente menores, como Cupiúba e Pariri, que registraram médias de 0,97443 e 0,95542, respectivamente. Esses valores indicam que o modelo encontrou maior dificuldade na classificação dessas espécies, possivelmente devido a características menos marcantes ou maior semelhança com outras classes presentes no conjunto de dados. No geral, o modelo apresentou um desempenho robusto, com médias de probabilidade superiores a 0,95 para todas as classes avaliadas.

As Figuras 38 apresenta a matriz não normalizada para o modelo Tangencial com Características Organolépticas. A matriz de confusão apresenta os números absolutos de acertos e erros. Todas as classes tiveram 48 amostras processadas, e os erros foram mínimos, sendo identificados principalmente em classes como Pariri e Cupiúba, que apresentaram desvios isolados. Esses achados reforçam o excelente desempenho geral do modelo e destacam áreas de possível aprimoramento.



Fonte: Autoria própria (2025).

Os erros de previsão do modelo são evidentes ao confundir as espécies Pariri com Maçaranduba e Cupiúba. As imagens das espécies confundidas estão apresentadas nas Figuras 39, 41 e 43. O primeiro erro de previsão ocorreu quando o modelo atribuiu uma probabilidade de


91% para Maçaranduba e apenas 7% para Pariri. A Figura 40 exibe a imagem da espécie que foi erroneamente classificada. Em outra análise, para a mesma espécie Pariri, o modelo atribuiu 43% para Imbuia 42a, 32% para Pariri e 22% para Sucupira Preta 42b. Por fim, o modelo atribuiu 100% de probabilidade para a espécie Pariri, conforme mostrado na Figura 44.

Figura 39 – Espécie Pariri classificada erroneamente como Maçaranduba.



Fonte: Autoria própria (2025).

Figura 40 – Espécie Maçaranduba.




Fonte: Autoria própria (2025).

Figura 41 – Espécie Pariri classificada erroneamente como Imbuia e Sucupira Preta.



Fonte: Autoria própria (2025).

Figura 42 – Espécie Imbuia e Sucupira Preta.




Fonte: Autoria própria (2025).

Figura 43 – Espécie Cupiúba classificada erroneamente como Imbuia Pariri.



Fonte: Autoria própria (2025).

Figura 44 – Espécie Pariri.



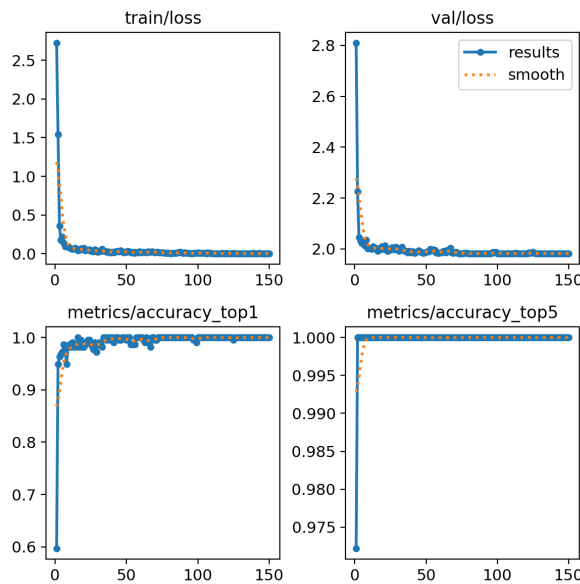
Fonte: Autoria própria (2025).

O valor acima da diagonal principal da matriz de confusão representa os casos em que a espécie Cupiúba foi prevista como uma espécie que aparece antes na ordem da matriz. Ou seja, o modelo classificou erroneamente a amostra como pertencente a uma espécie posicionada antes na matriz, em vez de identificá-la corretamente como Cupiúba. Esse tipo de erro pode indicar que o modelo confundiu as características da espécie real com as de outras que apresentam padrões ou tonalidades semelhantes.

4.11 Treinamento Modelo Híbrido com Características Organolépticas

O treinamento do modelo YOLOv8, integrando imagens transversais, tangenciais e características organolépticas, apresentou resultados promissores que demonstram a eficácia dessa abordagem híbrida. A Figura 45 ilustra o desempenho ao longo do treinamento, destacando a redução contínua das perdas (*loss*) e a evolução positiva das métricas de precisão.

Figura 45 – Treinamento e Validação para o Modelo Híbrido com Características Organolépticas.




Fonte: Autoria própria (2025).

Durante o treinamento, as métricas de *Accuracy_Top1* e *Accuracy_Top5* evidenciaram a eficiência do modelo na classificação, atingindo 99,5% e 100% nas últimas épocas, respectivamente. A estratégia de ajuste progressivo da taxa de aprendizado contribuiu significativamente para uma convergência estável, evitando oscilações e problemas como *overfitting*.

A matriz de confusão normalizada, apresentada na Figura 46, reflete o desempenho robusto do modelo, com precisão total em todas as classes analisadas. Esse resultado destaca a capacidade do modelo em identificar padrões complexos e realizar classificações precisas, mesmo em cenários onde há similaridade visual significativa entre as espécies.

Figura 46 – Matriz de Confusão Normalizada para o Modelo Híbrido.



Fonte: Autoria própria (2025).

Esses resultados evidenciam a eficácia do modelo híbrido na classificação de espécies florestais, com potencial para aplicações práticas no combate ao transporte ilegal de madeira e na identificação de espécies em diferentes condições ambientais. A abordagem híbrida revelou-se uma solução robusta para superar os desafios de diferenciação visual entre espécies com características similares.

4.12 Desempenho do Modelo Híbrido com Características Organolépticas

O modelo Híbrido com Características Organolépticas foi avaliado utilizando imagens de todas as classes presentes no conjunto de dados. A Tabela 10 apresenta a média das probabilidades de acerto por classe, juntamente com o número de imagens processadas para cada uma delas.

Os resultados obtidos mostram que a classe *Castanha-de-Macaco* atingiu a média máxima de probabilidade 1, indicando um desempenho excelente do modelo para essa espécie. Além disso, as classes *Muiracatiara*, *Imbuia*, *Jatobá* e *Tauari* também apresentaram valores de probabilidade próximos de 1, demonstrando uma alta precisão para a identificação dessas categorias.

Tabela 10 – Resumo das Predições e Imagens Processadas para o Modelo Híbrido com Características Organolépticas.

Classe	Média da Probabilidade	Imagens Processadas
Castanha-de-Macaco	1,00000	48
Muiracatiara	0,99999	48
Imbuia	0,99999	48
Jatobá	0,99998	48
Tuari	0,99998	48
Mogno	0,99997	48
Cedro	0,99996	48
Jacareúba	0,99995	48
Roxinho	0,99993	48
Cerejeira	0,99992	48
Sucupira-preta	0,99989	48
Maçaranduba	0,99971	48
Catingueira	0,99964	48
Cupiúba	0,99964	48
Angelim-vermelho	0,99942	48
Timbaúva	0,99867	48
Garapa	0,99866	48
Pariri	0,98925	48


Fonte: Autoria própria (2025).

Por outro lado, as classes *Timbaúva*, *Garapa* e *Pariri* registraram médias mais baixas em comparação às demais, com valores de 0,99867, 0,99866 e 0,98925, respectivamente. Apesar de ainda serem probabilidades elevadas, esses números sugerem que o modelo pode ter encontrado maior dificuldade na identificação dessas espécies.

De maneira geral, o modelo apresentou um desempenho consistente, com médias superiores a 0,98 para todas as classes avaliadas. A uniformidade no número de imagens processadas reforça a validade e a confiabilidade da análise realizada.

As Figuras 47 apresenta a matriz de confusão para o modelo. A matriz de confusão evidencia o número absoluto de acertos, mantendo a consistência em 48 amostras corretamente classificadas para cada classe.

Figura 47 – Matriz de confusão não normalizada



Fonte: Autoria própria (2025).

Os gráficos demonstram que o modelo alcançou um desempenho equilibrado e consistente em todas as classes, evidenciado pela ausência de confusões significativas entre as categorias. Diferentemente das análises anteriores, nas quais o modelo sempre cometia erros em alguma espécie, o modelo híbrido com características organolépticas proposto não cometeu nenhum erro de classificação. Essas análises da matriz de confusão corroboram os resultados apresentados na Tabela 10, reafirmando a robustez do modelo para a tarefa de classificação de espécies florestais.

4.13 Análise dos Modelos

As médias de probabilidade das predições para cada espécie e configuração de modelo são apresentadas na Tabela 11, evidenciando o impacto das características organolépticas na performance dos modelos avaliados. Observa-se que o modelo híbrido, que integra imagens transversais e tangenciais, combinado com características organolépticas, apresentou desempenho superior em relação às demais abordagens, alcançando uma média geral de probabilidade de 0,99914.

Este resultado destaca a importância da integração de múltiplas fontes de dados na tarefa de identificação de espécies arbóreas. O modelo superou não apenas os modelos baseados exclusivamente em imagens transversais (média de 0,99751) e tangenciais (média

de 0,99254), mas também aqueles que combinam imagens com características organolépticas de forma isolada, como o modelo transversal com características organolépticas (média de 0,99735) e o tangencial com características organolépticas (média de 0,99499).

A superioridade do modelo híbrido com características organolépticas é ainda mais evidente quando analisamos o desempenho em espécies específicas. Para a maioria das espécies, como Angelim-vermelho, Garapa, Maçaranduba e Roxinho, o modelo atingiu valores próximos ou iguais a 1, indicando alta confiabilidade nas predições. Mesmo em casos onde outras abordagens apresentaram desempenho satisfatório, como no modelo tangencial para Mogno (1) e o modelo transversal para Cerejeira (0,99999), o modelo híbrido com características organolépticas manteve ou superou esses resultados, reforçando sua robustez.

Tabela 11 – Média de probabilidade das predições para cada espécie nos diferentes modelos.

Espécie	Transversal	Tangencial	Híbrido	Transv. + Org.	Tang. + Org.	Híbrido + Org.
Angelim-vermelho	0,99928	0,98135	0,98765	0,99709	0,99929	0,99942
Castanha-de-Macaco	0,99996	0,99997	1,00000	0,99436	0,99971	1,00000
Catingueira	0,99988	0,99950	0,99943	0,99994	0,99575	0,99964
Cedro	0,99985	0,99995	0,99998	0,99990	0,99998	0,99996
Cerejeira	0,99999	0,99956	0,99964	1,00000	0,99996	0,99992
Cupiuba	0,99977	0,97049	0,99957	0,99998	0,97443	0,99964
Garapa	0,99805	0,95665	0,99877	0,99460	0,99978	0,99866
Imbuia	0,99997	0,99998	0,99998	0,99999	0,99997	0,99999
Jacareúba	0,99820	0,99894	0,99942	0,99931	1,00000	0,99995
Jatobá	0,99962	0,99960	0,99986	0,99883	0,99731	0,99998
Maçaranduba	0,97831	0,97754	0,99860	0,99483	0,99956	0,99971
Mogno	0,99989	1,00000	0,99913	0,99999	0,99971	0,99997
Muiracatiara	0,99992	0,99992	0,99999	0,99977	0,99993	0,99999
Pariri	0,98767	0,99115	0,98450	0,97414	0,95542	0,98925
Roxinho	0,99997	0,99353	0,99634	0,99987	0,99908	0,99993
Sucupira-preta	0,99986	0,99991	0,99994	0,99981	0,99077	0,99989
Tauari	0,99552	0,99989	0,99896	0,99994	0,99957	0,99998
Timbaúva	0,99946	0,99781	0,99825	0,99989	0,99963	0,99867
Média	0,99751	0,99254	0,99778	0,99735	0,99499	0,99914

5 CONCLUSÃO

Com o intuito de reconhecer espécies florestais do Bioma Amazônico, foram construídos dois conjuntos de dados com imagens macroscópicas capturadas por um microscópio digital USB. O primeiro dataset contém imagens transversais e o segundo, imagens tangenciais, abrangendo as mesmas 18 espécies, com 120 imagens por espécie (total de 2.160 imagens cada).

Para o treinamento dos modelos, os dados foram divididos em 50% para treinamento (1.080 imagens), 10% para validação (216 imagens) e 40% para teste (864 imagens). Utilizando o YOLOv8 como classificador, foram propostas seis abordagens para avaliar diferentes configurações na identificação das espécies. O modelo baseado em imagens transversais atingiu uma acurácia de 0,99751, enquanto o modelo tangencial apresentou 0,99254. A combinação das duas perspectivas resultou em um modelo híbrido com acurácia de 0,99778.

A inclusão de características organolépticas afetou os resultados de maneira distinta: o modelo transversal sofreu uma ligeira redução para 0,99735, enquanto o tangencial melhorou para 0,99499. Destaca-se que o modelo híbrido, ao incorporar essas informações, obteve o melhor desempenho, alcançando uma acurácia de 0,99914. A análise das matrizes de confusão demonstrou que as características organolépticas foram fundamentais para diferenciar espécies com padrões visuais semelhantes, tendo menor impacto na distinção de espécies com diferenças visuais bem definidas – evidenciando que sua relevância varia conforme a complexidade taxonômica.

O modelo híbrido com características organolépticas apresentou a maior média entre todas as abordagens, ressaltando a importância da integração de múltiplas fontes de dados para a classificação de espécies florestais. Ademais, sua robustez frente a condições adversas – como ruído, variações de iluminação e pequenas deformações nas amostras – reforça a aplicabilidade do sistema em monitoramento ambiental e fiscalização em campo.

A tecnologia proposta não só reduz custos operacionais como também automatiza a identificação das espécies, eliminando a dependência exclusiva de análises manuais, que são demoradas e suscetíveis a erros. Dessa forma, apresenta-se como uma ferramenta inovadora para combater a exploração madeireira ilegal, permitindo maior controle sobre a origem e comercialização da madeira no Bioma Amazônico e contribuindo para a preservação ambiental.

5.1 Perspectivas Futuras

Os resultados deste estudo estabelecem bases sólidas para avanços futuros, tais como:

- Expansão do conjunto de dados, aumentando o número de espécies e amostras;
- Otimização do modelo híbrido por meio de arquiteturas mais avançadas;

- Integração do sistema em plataformas de monitoramento em tempo real para aplicação prática em campo;
- Adaptação da metodologia para outros biomas ameaçados, ampliando seu impacto na conservação ambiental.

Com esses aprimoramentos, espera-se consolidar o uso da inteligência artificial como uma ferramenta eficiente e acessível para a preservação da biodiversidade, tornando a identificação de espécies mais precisa e aplicável em larga escala.

REFERÊNCIAS

- ANDINA, D. *et al.* Deep learning for computer vision: A brief review. **Computational Intelligence and Neuroscience**, Hindawi, v. 2018, p. 7068349, 2018. ISSN 1687-5265. Disponível em: <https://www.hindawi.com/journals/cin/2018/7068349/>. Acesso em: 08 out. 2023.
- ARAUJO, H. J. B. de. Caracterização do material madeira. **Embrapa**, Embrapa, dez. 2020. Disponível em: <https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1120281/1/26971.pdf>. Acesso em: 09 set. 2023.
- BOCHKOVSKIY, A.; WANG, C.-Y.; LIAO, H.-Y. M. **YOLOv4: Optimal Speed and Accuracy of Object Detection**. 2020. Disponível em: <https://arxiv.org/abs/2004.10934>. Acesso em: 01 out. 2023.
- BOTOSSO, P. C. Identificação macroscópica de madeiras: guia prático e noções básicas para o seu reconhecimento. **Embrapa**, Embrapa, maio 2011. Disponível em: <https://www.infoteca.cnptia.embrapa.br/handle/doc/894373>. Acesso em: 09 set. 2023.
- BOULTON, C. A.; LENTON, T. M.; BOERS, N. Pronounced loss of amazon rainforest resilience since the early 2000s. **Nature Climate Change**, Nature, v. 12, p. 271–278, mar. 2022. Disponível em: <https://doi.org/10.1038/s41558-022-01287-8>. Acesso em: 22 ago. 2023.
- BRASILEIRO, L. de P. F. S. F. **Banco de Dados de Espécies de Madeiras Brasileiras**. 2024. Disponível em: <https://lpf.florestal.gov.br/pt-br/>. Acesso em: 11 nov. 2024.
- BURGER, A.; RICHTER, H. G. **Wood Microscopy**. [S.l.]: Springer, 1991.
- CHAI, J. *et al.* Deep learning in computer vision: A critical review of emerging techniques and application scenarios. **Machine Learning with Applications**, v. 6, p. 100134, 2021. ISSN 2666-8270. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2666827021000670>. Acesso em: 08 out. 2023.
- COLABORATORY, G. **Google Colaboratory**. 2023. Disponível em: <https://cloud.google.com/colab/docs>. Acesso em: 22 out. 2023.
- DEVELOPERS, G. **Curso Rápido de Machine Learning: Acurácia, Precisão e Recall**. 2024. Disponível em: <https://developers.google.com/machine-learning/crash-course/classification/accuracy-precision-recall?hl=pt-br>. Acesso em: Acessado em: 26 fev. 2024.
- DEVRIES, T.; TAYLOR, G. W. Improved regularization of convolutional neural networks with cutout. **CoRR**, abs/1708.04552, 2017. Disponível em: <http://arxiv.org/abs/1708.04552>. Acesso em: 27 nov. 2024.
- ELLWANGER, J. H. *et al.* Beyond diversity loss and climate change: Impacts of Amazon deforestation on infectious diseases and public health. **Anais da Academia Brasileira de Ciências**, Scielo, n. 1, p. 92, 2020. Disponível em: <https://www.scielo.br/j/aabc/a/frVhxyPq4NLCsKTZPJMzV8J/?lang=en>. Acesso em: 22 ago. 2023.
- FIGUEROA-MATA, G. *et al.* Using deep convolutional networks for species identification of xylotheque samples. **2018 IEEE International Work Conference on Bioinspired Intelligence (IWOBI)**, Universidade Tecnológica Federal do Paraná, p. 1–9, jul. 2018. Disponível em: <https://ieeexplore.ieee.org/document/8464216>. Acesso em: 22 ago. 2023.

GATTI, L. V. *et al.* Amazonia as a carbon source linked to deforestation and climate change. **Nature Climate Change**, Nature, v. 595, p. 388–393, mar. 2021. Disponível em: <https://doi.org/10.1038/s41586-021-03629-6>. Acesso em: 22 ago. 2023.

GEUS, A. R. de *et al.* An analysis of timber sections and deep learning for wood species classification. **Multimedia Tools and Applications**, Springer, v. 79, n. 45, p. 34513–34529, 2020. Disponível em: <https://doi.org/10.1007/s11042-020-09212-x>. Acesso em: 28 mai. 2023.

GHAPAR, H. A. *et al.* New Feature Extraction for Wood Species Recognition System via Statistical Properties of Line Distribution. **2021 International Conference on Electrical, Communication, and Computer Engineering (ICECCE)**, IEEE Xplore, p. 1–5, fev. 2021. Disponível em: https://ieeexplore.ieee.org/abstract/document/9514115?casa_token=RMjwFrNlalkAAAAA:6tAX9R42bMDOX-EAr2KzV6xKVogMnBL-G9g2JuCOfxSJryikIDQ9I-52CZ07b2W1bjC45_lv8Y_Amb4. Acesso em: 22 ago. 2023.

GONZALEZ, R. C.; WOODS, R. E. **Processamento Digital de Imagens**. 3. ed. São Paulo: Pearson / Prentice Hall, 2010.

HOWARD, A. G. **Some Improvements on Deep Convolutional Neural Network Based Image Classification**. 2013. Disponível em: <https://arxiv.org/abs/1312.5402>. Acesso em: 21 nov. 2024.

HUSSAIN, M. Yolo-v1 to yolo-v8, the rise of yolo and its complementary nature toward digital manufacturing and industrial defect detection. **Machines**, v. 11, n. 7, 2023. ISSN 2075-1702. Disponível em: <https://www.mdpi.com/2075-1702/11/7/677>. Acesso em: 11 dez. 2024.

HWANG, S.-W.; SUGIYAMA, J. Computer vision-based wood identification and its expansion and contribution potentials in wood science: A review. **Plant Methods**, v. 17, n. 1, p. 47, April 28 2021. ISSN 1746-4811. Disponível em: <https://doi.org/10.1186/s13007-021-00746-1>. Acesso em: 08 out. 2023.

IPT, I. de P. T. **Banco de Dados de Madeiras do Brasil**. 2024. Disponível em: <https://madeiras.ipt.br/>. Acesso em: 11 nov. 2024.

KAI, M. H. *et al.* Reconhecimento de espécies florestais utilizando visão computacional. Anais do XII Seminário de Extensão e Inovação e XXVII Seminário de Iniciação Científica e Tecnológica da UTFPR, dez. 2022. Disponível em: www.even3.com.br/Anais/seisicite2022/549155-RECONHECIMENTO-DE-ESPECIES-FLORESTAIS-UTILIZANDO-VISAO-COMPUTACIONAL. Acesso em: 22 ago. 2023.

KOCZAN, G.; KARWAT, Z.; KOZAKIEWICZ, P. An attempt to unify the brinell, janka and monnin hardness of wood on the basis of meyer law. **Journal of Wood Science**, v. 67, n. 1, p. 7, 2021. ISSN 1611-4663. Disponível em: <https://doi.org/10.1186/s10086-020-01938-4>. Acesso em: 28 nov. 2024.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. **Commun. ACM**, Association for Computing Machinery, New York, NY, USA, v. 60, n. 6, p. 84–90, maio 2017. ISSN 0001-0782. Disponível em: <https://doi.org/10.1145/3065386>. Acesso em: 17 nov. 2024.

KIRBAŞ İsmail; ÇIFCI, A. An effective and fast solution for classification of wood species: A deep transfer learning approach. **Ecological Informatics**, Ecological Informatics, n. 69, p. 101633, jul. 2022. Disponível em: <https://doi.org/10.1016/j.ecoinf.2022.101633>. Acesso em: 22 ago. 2023.

LUO, C.; HAO, Y.; TONG, Z. Research on digital image processing technology and its application. *In: Proceedings of the 2018 8th International Conference on Management, Education and Information (MEICI 2018)*. Atlantis Press, 2018. p. 587–592. ISBN 978-94-6252-640-2. ISSN 1951-6851. Disponível em: <https://doi.org/10.2991/meici-18.2018.116>. Acesso em: 08 out. 2023.

MALHI, Y. *et al.* Climate Change, Deforestation, and the Fate of the Amazon. **Science**, Science, v. 319, n. 5860, p. 169–172, fev. 2008. Disponível em: <https://www.science.org/doi/abs/10.1126/science.1146961>. Acesso em: 22 ago. 2023.

MARIANO, D. Métricas de avaliação em machine learning: acurácia, sensibilidade, precisão, especificidade e f-score. *In: ____*. [s.n.], 2021. ISBN 9786599275326. Disponível em: https://www.researchgate.net/publication/353001655_Metricas_de_avaliacao_em_machine_learning_acuracia_sensibilidade_precisao_especificidade_e_F-score. Acesso em: 28 nov. 2024.

MEAURIO, G. F.; FILHO, P. L. d. P. Criação de datasets de imagens florestais. UTFPR, Francisco Beltrão (PR), 2024. Disponível em: <https://www.even3.com.br/anais/seisicite2024/961440-CRIACAO-DE-DATASETS-DE-IMAGENS-FLORESTAIS>. Acesso em: 21 dez. 2024.

NEETHU, S.; SYLA, L. B. Wood Species Recognition Using Machine Learning. **2021 Fourth International Conference on Microelectronics, Signals & Systems (ICMSS)**, IEEE Xplore, p. 1–6, fev. 2021. Disponível em: <https://ieeexplore.ieee.org/document/9673601>. Acesso em: 22 ago. 2023.

OLIVEIRA, W. de. Software para reconhecimento de espécies florestais a partir de imagens digitais de madeiras utilizando deep learning. Universidade Tecnológica Federal do Paraná, mar. 2018. Disponível em: <http://repositorio.utfpr.edu.br/jspui/handle/1/3189>. Acesso em: 22 ago. 2023.

PAULA FILHO, P. L. de. **Reconhecimento de espécies florestais através de imagens macroscópicas**. 2012. Tese (Doutorado) — Universidade Federal do Paraná, 2012. Disponível em: <https://acervodigital.ufpr.br/handle/1884/29781>. Acesso em: 8 set. 2023.

PONNUSAMY, R.; SATHIAMOORTHY, S.; KALIYAMOORTHY, M. A review of image classification approaches and techniques. 03 2020. Acesso em: 08 out. 2023.

PYTHONBRASIL. **Introdução ao Python**. 2023. Disponível em: <https://www.python.org/doc/>. Acesso em: 11 nov. 2024.

REDMON, J. *et al.* **You Only Look Once: Unified, Real-Time Object Detection**. 2016. Disponível em: <https://arxiv.org/abs/1506.02640>. Acesso em: 26 mai. 2024.

REDMON, J.; FARHADI, A. **YOLO9000: Better, Faster, Stronger**. 2016. Disponível em: <https://arxiv.org/abs/1612.08242>. Acesso em: 26 mai. 2024.

REDMON, J.; FARHADI, A. **YOLOv3: An Incremental Improvement**. 2018. Disponível em: <https://arxiv.org/abs/1804.02767>. Acesso em: 26 mai. 2024.

SANTOS, S. N. C. dos. Análise estrutural e de superfície de madeiras submetidas a tratamento térmico e degradadas pelo fungo pycnoporus sanguineus. Escola de Engenharia de São Carlos, mar. 2015. Disponível em: <https://www.teses.usp.br/teses/disponiveis/18/18158/tde-22092015-105627/pt-br.php>. Acesso em: 22 ago. 2023.

- SIBLINI, W. *et al.* Master your metrics with calibration. *In: ____*. **Advances in Intelligent Data Analysis XVIII**. Springer International Publishing, 2020. p. 457–469. ISBN 9783030445843. Disponível em: http://dx.doi.org/10.1007/978-3-030-44584-3_36. Acesso em: 28 nov. 2024.
- SOLIMANI, F. *et al.* Optimizing tomato plant phenotyping detection: Boosting yolov8 architecture to tackle data complexity. **Computers and Electronics in Agriculture**, v. 218, p. 108728, 2024. ISSN 0168-1699. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169924001194>. Acesso em: 26 mai. 2024.
- SOUZA, R. B. *et al.* Efeitos da extração de madeira sobre a biodiversidade em florestas tropicais. **Natural Resources**, Natural Resources, v. 11, p. 3, jul. 2021. Disponível em: <https://doi.org/10.6008/CBPC2237-9290.2021.003.0005>. Acesso em: 22 ago. 2023.
- SZÜCS, C. A. *et al.* **ESTRUTURAS DE MADEIRA**. [S.l.], 2015. Disponível em: https://moodle.ufsc.br/pluginfile.php/1313798/mod_resource/content/0/Apostilamadeiras2015-1.pdf. Acesso em: 07 out. 2023.
- TERVEN, J.; CórDOVA-ESPARZA, D.-M.; ROMERO-GONZÁLEZ, J.-A. A comprehensive review of yolo architectures in computer vision: From yolov1 to yolov8 and yolo-nas. **Machine Learning and Knowledge Extraction**, MDPI AG, v. 5, n. 4, p. 1680–1716, nov. 2023. ISSN 2504-4990. Disponível em: <http://dx.doi.org/10.3390/make5040083>. Acesso em: 26 mai. 2024.
- ULTRALYTICS. **Ultralytics Glossary**. 2024. Disponível em: <https://www.ultralytics.com/glossary>. Acesso em: 11 nov. 2024.
- WANG, C.-K.; ZHAO, P. Classification of wood species using spectral and texture features of transverse section. **European Journal of Wood and Wood Products**, European Journal of Wood and Wood Products, n. 79, p. 1283–1296, jun. 2021. Disponível em: <https://doi.org/10.1007/s00107-021-01728-9>. Acesso em: 22 ago. 2023.
- WHEELER, E. A.; BAAS, P. Wood identification -a review. **IAWA Journal**, Brill, v. 19, n. 3, p. 241 – 264, maio 1998. Disponível em: <https://doi.org/10.1163/22941932-90001528>. Acesso em: 19 set. 2023.
- WU, F. *et al.* Wood identification based on longitudinal section images by using deep learning. **Wood Science and Technology**, Wood Science and Technology, n. 55, p. 553–563, ago. 2021. Disponível em: <https://doi.org/10.1007/s00226-021-01261-1>. Acesso em: 22 ago. 2023.
- ZHANG, H. *et al.* **mixup: Beyond Empirical Risk Minimization**. 2018. Disponível em: <https://arxiv.org/abs/1710.09412>. Acesso em: 01 out. 2023.
- ZHONG, Z. *et al.* Random erasing data augmentation. **Proceedings of the AAAI Conference on Artificial Intelligence**, v. 34, n. 07, p. 13001–13008, Apr 2020. Disponível em: <https://ojs.aaai.org/index.php/AAAI/article/view/7000>. Acesso em: 17 dez. 2024.
- ZHUANG, F. *et al.* **A Comprehensive Survey on Transfer Learning**. 2020. Disponível em: <https://arxiv.org/abs/1911.02685>. Acesso em: 25 out. 2023.