


UNIVERSIDADE FEDERAL DO PARANÁ

CIBELLE AMARAL REIS

USO DA INTELIGÊNCIA ARTIFICIAL PARA IDENTIFICAÇÃO/DISTINÇÃO
DE MADEIRAS COM BASE EM IMAGENS MACROSCÓPICAS

CURITIBA

2024



CIBELLE AMARAL REIS

USO DA INTELIGÊNCIA ARTIFICIAL PARA IDENTIFICAÇÃO/DISTINÇÃO
DE MADEIRAS COM BASE EM IMAGENS MACROSCÓPICAS

Tese apresentada ao curso de Pós-Graduação em Engenharia Florestal, Setor de Ciências Agrárias, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutora em Engenharia Florestal. Área de Concentração: Tecnologia e Utilização de Produtos Florestais.

Orientadora: Profa. Dra. Silvana Nisgoski

Coorientadora: Profa. Dra. Graciela Inés Bolzon de Muñiz

Coorientadora: Profa. Dra. Simone Ribeiro Morrone

CURITIBA

2024

Ficha catalográfica elaborada pela
Biblioteca de Ciências Florestais e da Madeira - UFPR

Reis, Cibelle Amaral

Uso da inteligência artificial para identificação/distinção de madeiras com base em imagens macroscópicas / Cibelle Amaral Reis. - Curitiba, 2024.

1 recurso on-line : PDF

Orientadora: Profa. Dra. Silvana Nisgoski

Coorientadoras: Profa. Dra. Graciela Inés Bolzon de Muñiz

Profa. Dra. Simone Ribeiro Morrone

Tese (Doutorado) - Universidade Federal do Paraná, Setor de Ciências Agrárias. Programa de Pós-Graduação em Engenharia Florestal. Defesa: Curitiba, 25/03/2024.

1. Madeira - Identificação. 2. Madeira - Classificação. 3. Inteligência artificial (Aplicações científicas). 4. Visão por computador. 5. Redes neurais Computação). 7. Aprendizado de máquina. 8. Processamento de imagens - Técnicas digitais. I. Nisgoski, Silvana. II. Bolzón de Muñiz, Graciela Inés. III. Morrone, Simone Ribeiro. IV. Universidade Federal do Paraná, Setor de Ciências Agrárias. V. Título.

CDD - 634.9

CDU - 630*81

634.0.811

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação ENGENHARIA FLORESTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **CIBELLE AMARAL REIS** intitulada: **USO DA INTELIGÊNCIA ARTIFICIAL PARA IDENTIFICAÇÃO/DISTINÇÃO DE MADEIRAS**

COM BASE EM IMAGENS MACROSCÓPICAS, sob orientação da Profa. Dra. SILVANA NISGOSKI, que após terem inquirido a aluna e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de doutora está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 25 de Março de 2024.

Assinatura Eletrônica

27/03/2024 13:16:13.0

SILVANA NISGOSKI

Presidente da Banca Examinadora

Assinatura Eletrônica

28/03/2024 15:01:32.0

CLÁUDIA FRANCA BARROS

Avaliador Externo (INSTITUTO DE PESQUISAS JARDIM BOTANICO
DO RIO DE JANEIRO)

Assinatura Eletrônica

27/03/2024 12:54:02.0

ERIKA AMANO

Avaliador Externo (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica

27/03/2024 14:39:02.0

MARTHA ANDREIA BRAND

Avaliador Externo (UNIVERSIDADE DO ESTADO DE SANTA
CATARINA)

Assinatura Eletrônica

27/03/2024 13:24:51.0

HELENA CRISTINA VIEIRA

Avaliador Externo (UNIVERSIDADE FEDERAL RURAL DE
PERNAMBUCO)

Dedico este trabalho aos meus avós Afonso Feitosa Reis (*in memoriam*) e Maria do Amparo Coutinho Reis, e à querida amiga Zarife Ayub (*in memoriam*).

AGRADECIMENTOS

Agradeço à minha família, em especial aos meus pais, Bernadete Amaral Reis e Afonso Filho, pelo apoio e incentivo. Mainha foi a minha primeira professora, incentivando meu amor pela leitura e estudos, iniciando quando lia histórias diariamente para mim quando ainda estava no berço. Painho sempre foi o exemplo de cientista e mal sabia ele o amor e fascínio pela ciência que despertaria enquanto, sem sua autorização, brincava com as peças 3D de seus modelos atômicos e com seus *gadgets* tecnológicos.

Tenho imensurável gratidão a todas as professoras e professores que foram meus mestres – que me ensinaram desde de como desenhar letras, perpassando por ciências, álgebra, e ao mais diversos e complexos ensinamentos da graduação, mestrado e doutorado. Neste ínterim, agradeço enormemente os esforços, dedicação e paciência do comitê orientador que me acompanhou na empreitada que foi a construção dessa tese: Profa. Dra. Silvana Nisgoski, Profa. Dra. Graciela I. B. de Muñiz e Profa. Dra. Simone R. Morrone. Sempre foi de suma importância a representação, inspiração e admiração do trabalho de mulheres engenheiras e cientistas. Estendo os meus agradecimentos ao comitê avaliador por dispor de seu tempo e conhecimento para enriquecer este trabalho: Profa. Dra. Helena C. Vieira (UFRPE), Profa. Dra. Martha A. Brand (UDESC), Profa. Dra. Erika Amano (UFPR) e Dra. Cláudia F. Barros (Instituto de Pesquisas Jardim Botânico do Rio de Janeiro).

Gratidão à toda equipe do LANAQM UFPR, em especial a todo acolhimento, apoio, ajuda, prontidão e amizade da Dra. Eliane Silva, a quem acompanhou e foi peça fundamental para o sucesso desta minha jornada na pós-graduação. Agradeço ao Prof. Dr. Pedro L. de Paula (UTFPR) e ao Msc. Jandrei Sartori Spancerski (UTFPR) por todo o apoio, paciência e disponibilidade que possibilitaram a concretização dos aspectos estatísticos e tecnológicos para o desenvolvimento desta pesquisa.

Agradeço às amigas que tanto me apoiaram nos desafios diários: Luísa Afonso, Daniela Minini, Juliana Rodrigues, Maria Eduarda Goulart, Emmanoella Guaraná, Nathalia Smangorzevski e Amanda Costa. Obrigada pelo carinho, cafezinhos e acolhimento. Um agradecimento especial ao Theobaldo por todo o apoio durante as intermináveis horas de escrita.

Agradeço à Universidade Federal do Paraná, ao Setor de Ciências Agrárias e ao Programa de Pós-Graduação em Engenharia Florestal pela infraestrutura e apoio

de toda a equipe de técnicos e docentes essenciais para a realização desta pesquisa e meu aprimoramento como profissional. Agradeço ao Centro de Assessoria e Publicação Acadêmica (CAPA – UFPR) pela oportunidade de participar e aprender tanto com a incrível equipe dessa organização.

Por fim, agradeço ao Ministério da Educação e à CAPES pela concessão de bolsa para a realização deste trabalho de doutorado.

RESUMO

Nas últimas décadas o uso de imagens em conjunto com técnicas computacionais tem sido estudado para a identificação e distinção de madeiras. Os esforços mais recentes têm se concentrado no uso de redes neurais artificiais, aprendizado profundo e visão computacional para tarefas de classificação. Para compreensão desse cenário, uma revisão bibliométrica foi realizada utilizando uma combinação de várias palavras-chave relacionadas à identificação de madeiras e identificação por visão computacional na plataforma *Scopus*, focando-se apenas em artigos científicos. Após a triagem, um total de 44 artigos foram analisados e o estado da arte deste tema construído. Neste universo, destacam-se como os principais produtores de conhecimento o Brasil e Estados Unidos, demonstrando a relevância não só pelo quantitativo de espécies comercializadas, mas também no desenvolvimento de técnicas e tecnologia. Além disso, destaca-se o uso de redes neurais convolucionais em diferentes configurações. Contudo, mesmo com o rápido desenvolvimento de ferramentas utilizando *transfer learning*, não foi identificado o uso de maneira expressiva de arquiteturas mais complexas e que exigem menor input do operador, como o YOLO, comumente utilizado para a detecção de objetos e já empregado na indústria madeireira para classificação de qualidade da madeira em indústrias. Em razão disso, foi testada a eficiência de YOLOv8 para a identificação/distinção de madeiras a partir de 5 bancos de dados de imagens macroscópicas transversais obtidas com diferentes equipamentos (celular, câmera digital, estereomicroscópio, microscópio USB), diferentes ampliações e preparo de superfície distintos (lixas de diferentes grãos, lâmina de micrótomo de deslize, corte não homogêneo com objeto cortante). Todos os testes realizados com YOLOv8 apresentaram acurácia acima de 99% e métricas de desempenho que indicam positivamente a precisão, sensibilidade e capacidade preditiva dos modelos e algoritmo aplicado. Com um volume total de mais de 11 mil imagens, pode-se constatar o grande potencial de YOLOv8 para a identificação/distinção de madeiras por meio do modo de classificação do algoritmo. Esses resultados se destacam especialmente em razão das imagens terem sido obtidas com diferentes equipamentos, diferente ampliação e preparo de superfície distintos, indicando seu potencial para aplicação em sistemas mais complexos, robustos e universais de identificação/distinção já que sua acurácia não foi afetada (ou pouco afetada) pelas fontes mais comuns de variação. Ou seja, estes resultados podem indicar o YOLOv8 como uma alternativa viável para um sistema de identificação mundial aberto e alimentado por diversos especialistas, laboratórios e outras instituições credenciadas, que facilitaria a identificação de madeiras por leigos ou órgãos fiscalizadores de maneira mais rápida e menos onerosa.

Palavras-chave: Visão computacional; YOLO; redes neurais convolucionais; reconhecimento de espécies; espécies madeireiras.

ABSTRACT

In recent decades, the use of images in combination with computational techniques has been studied for the identification and distinction of wood. The most recent efforts have focused on the use of artificial neural networks, deep learning and computer vision for classification tasks. To understand this scenario, a bibliometric review was carried out using a combination of various keywords related to wood identification and computer vision-based identification on the Scopus platform, focusing only on scientific articles. After screening, a total of 44 articles were analyzed and the state of the art of this topic was developed. In this context, Brazil and the United States stand out as the main producers of knowledge, demonstrating their relevance not only in terms of the number of commercialized species, but also in terms of techniques and technological development. In addition, the use of convolutional neural networks in different configurations stands out. However, even with the rapid development of tools using transfer learning, there has been no significant use of more complex architectures that require less input from the operator, such as YOLO, which is commonly used for object detection and is already used in the timber industry to classify wood quality. For this reason, the efficiency of YOLOv8 for identifying/distinguishing wood was tested using 5 databases of macroscopic cross-sectional images obtained with different equipment (cell phone, digital camera, stereomicroscope, USB microscope), different magnification and different surface preparation (sandpaper with different grits, sliding microtome blade, nonhomogeneous cut with sharp object). All the tests performed with YOLOv8 had an accuracy of over 99% and performance metrics that positively indicate the accuracy, sensitivity and predictive capacity of the models and algorithm applied. With a total volume of more than 11,000 images, there is a considerable potential in YOLOv8 for identifying/distinguishing wood using the algorithm's classification mode. These results stand out in particular because the images were taken with different equipment, different magnification and different surface preparation, indicating its potential for application in more complex, robust and universal identification/distinction systems, since its accuracy was not affected (or little affected) by the most common sources of variation. In other words, these results may indicate YOLOv8 as a viable alternative for an open global identification system fed by various experts, laboratories and other accredited institutions, which would facilitate the identification of wood by laypeople or inspection bodies in a faster and more cost-effective manner.

Keywords: Computer vision; YOLO; convolutional neural networks; species recognition; wood species.

LISTA DE FIGURAS

FIGURA 1 – NÚMERO DE DOCUMENTOS POR AUTOR (TOP 10).....	34
FIGURA 2 – RELAÇÃO DAS PRINCIPAIS INSTITUIÇÕES DE AFILIAÇÃO DOS AUTORES (TOP 10	35
FIGURA 3 – PRINCIPAL REDE DE CLUSTERS DE INTERLIGAÇÃO ENTRE OS AUTORES.....	36
FIGURA 4 – MAPA DE COLABORAÇÃO ENTRE PAÍSES.....	36
FIGURA 5 – TRABALHOS MAIS CITADOS (TOP 10)	37
FIGURA 6 – NÚMERO DE DOCUMENTOS POR AGÊNCIA DE FOMENTO	38
FIGURA 7 – QUANTIDADE DE ARTIGOS PUBLICADOS POR ANO	39
FIGURA 8 – DOCUMENTOS POR ÁREA DE CONHECIMENTO.....	39
FIGURA 9 – PRINCIPAIS PERIÓDICOS (TOP 5).....	40
FIGURA 10 – TOP 15 PALAVRAS-CHAVE MAIS RELEVANTES (AUTORES).....	41
FIGURA 11 – REDE DE CONEXÕES ENTRE PALAVRAS-CHAVE	42
FIGURA 12 – TOP 15 TERMOS MAIS RELEVANTES PARA O TÍTULO	43
FIGURA 13 – SISTEMA DE OBTENÇÃO DE IMAGENS	80
FIGURA 14 – SISTEMA PARA OBTENÇÃO DE IMAGENS	84
FIGURA 15 – ARQUITETURA DA YOLOV8	90
FIGURA 16 – MATRIZ DE CONFUSÃO NORMALIZADA DO TESTE 1	95
FIGURA 17 – IMAGEM IDENTIFICADA INCORRETAMENTE E ESPÉCIE COM A QUAL FOI CONFUNDIDA	97
FIGURA 18 – GRÁFICOS DE PERDAS VERSUS TREINAMENTO, PERDAS VERSUS VALIDAÇÃO E ACURÁCIA TOP1 E TOP 5 – TESTE 1	98
FIGURA 19 – MATRIZ DE CONFUSÃO NORMALIZADA DO TESTE 2	100
FIGURA 20 – IMAGENS IDENTIFICADAS INCORRETAMENTE NO TESTE 2.....	102
FIGURA 21 – GRÁFICOS DE PERDAS VERSUS TREINAMENTO, PERDAS VERSUS VALIDAÇÃO E ACURÁCIA TOP1 E TOP 5 DO TESTE 2	105
FIGURA 22 – MATRIZ DE CONFUSÃO NORMALIZADA DO TESTE 3	106
FIGURA 23 – IMAGENS IDENTIFICADAS INCORRETAMENTE NO TESTE 3.....	108
FIGURA 24 – GRÁFICOS DE PERDAS VERSUS TREINAMENTO, PERDAS VERSUS VALIDAÇÃO E ACURÁCIA TOP1 E TOP 5 DO TESTE 3	110

FIGURA 25 – IMAGENS IDENTIFICADAS INCORRETAMENTE NO TESTE 4 – GRUPO 1.....	112
FIGURA 26 – IMAGENS IDENTIFICADAS INCORRETAMENTE NO TESTE 4 – GRUPO 2.....	113
FIGURA 27 – IMAGENS IDENTIFICADAS INCORRETAMENTE NO TESTE 4 – PARTE 3, GRUPO 1.....	117
FIGURA 28 – IMAGENS IDENTIFICADAS INCORRETAMENTE NO TESTE 4 – PARTE 3, GRUPO 2.....	119
FIGURA 29 – IMAGENS MACROSCÓPICAS TRANSVERSAIS DAS 7 ESPÉCIES ESTUDADAS (<i>DATASET CAATINGA</i>).....	142
FIGURA 30 – IMAGENS MACROSCÓPICAS TRANSVERSAIS DAS 26 ESPÉCIES ESTUDADAS (<i>DATASET MATA ATLÂNTICA</i>).....	143
FIGURA 31 – IMAGENS MACROSCÓPICAS TRANSVERSAIS DAS 41 ESPÉCIES ESTUDADAS (<i>FOREST SPECIES DATABASE - MACROSCOPIC</i>)	144
FIGURA 32 – IMAGENS MACROSCÓPICAS TRANSVERSAIS DAS 46 ESPÉCIES ESTUDADAS (<i>BANCO DE DADOS ENDANGERED FOREST SPECIES</i>).....	145

LISTA DE TABELAS

TABELA 1 – RELAÇÃO DE TESTES, COMBINAÇÕES DE BANCO DE DADOS E RESPECTIVOS NÚMEROS DE IMAGENS.....	77
TABELA 2 – RELAÇÃO DE ESPÉCIES BANCO DE DADOS CAATINGA.....	78
TABELA 3 – RELAÇÃO DE ESPÉCIES E RESPECTIVAS INFORMAÇÕES DO BANCO DE DADOS MATA ATLÂNTICA.....	81
TABELA 4 – RELAÇÃO DE ESPÉCIES E RESPECTIVAS INFORMAÇÕES DO BANCO DE DADOS <i>FOREST SPECIES DATABASE – MACROSCOPIC</i>	83
TABELA 5 – RELAÇÃO DE ESPÉCIES E RESPECTIVAS INFORMAÇÕES DO BANCO DE DADOS <i>ENDANGERED FOREST SPECIES</i>	84
TABELA 6 – RELAÇÃO DE ESPÉCIES E RESPECTIVAS INFORMAÇÕES DO BANCO DE DADOS RESULTANTE DA COMBINAÇÃO DE TODOS OS BANCOS.....	86
TABELA 7 – MÉTRICAS DA ETAPA DE VALIDAÇÃO DO TESTE 1.....	96
TABELA 8 - MÉTRICAS DA ETAPA DE VALIDAÇÃO DO TESTE 2.....	104
TABELA 9 – MÉTRICAS RESULTANTES DO MODELO PERFORMADO NO TESTE 3.....	109
TABELA 10 – MÉTRICAS DO TESTE 4, PARTE 2.....	113

LISTA DE QUADROS

QUADRO 1 – INFORMAÇÕES SOBRE A CÂMERA E AQUISIÇÃO DE IMAGENS	79
QUADRO 2 – ESPECIFICAÇÕES DA PLACA DE VÍDEO CUDA NVIDIA GeForce RTX 4070 Ti	89
QUADRO 3 – ESPECIFICAÇÕES DA YOLOV8M	89
QUADRO 4 – PARÂMETROS DETERMINADOS PARA ADAMW	92

LISTA DE ABREVIATURA E SIGLAS

FAO	Organização das Nações Unidas para Alimentação e Agricultura
GLCM	<i>Gray Level Co-occurrence matrix</i> – Matrix de coocorrência no nível de cinza
IA	Inteligência Artificial
IBÁ	Indústria Brasileira de Árvores
K-NN	<i>K- nearest neighbor</i> – Vizinho mais próximo
LBP	<i>Local Binary Patterns</i> – Modelo local binário
MRI	Análise de imagem por ressonância magnética
NIR	<i>Near infrared</i> - Infravermelho próximo
PIB	Produto Interno Bruto
ResNET	<i>Residual Neural Network</i> – Rede Neural Residual
RNA	Redes Neurais Artificiais
RNC	Redes Neurais Convolucionais
SVM	<i>Support Vector Machine</i> – Máquinas de Vetores Suporte
USDA	Departamento de Agricultura dos Estados Unidos
USFS	Serviço Florestal dos Estados Unidos
VGG	<i>Visual Geometry Group</i> – Grupo de Geometria Visual
YOLO	<i>You only look once</i> – Você olha somente uma vez

SUMÁRIO

INTRODUÇÃO GERAL	17
OBJETIVOS	20
Objetivo geral	20
Objetivos específicos	20
ESTRUTURA DA DISSERTAÇÃO	21
REFERÊNCIAS	22
CAPÍTULO 1	25
PANORAMA DO USO DE IMAGENS E INTELIGÊNCIA ARTIFICIAL NA IDENTIFICAÇÃO E DISTINÇÃO DE MADEIRAS	25
1.1 INTRODUÇÃO	27
1.2 OBJETIVOS	30
1.2.1 Objetivo geral	30
1.2.2 Objetivos específicos	30
1.3 METODOLOGIA	31
1.4 RESULTADOS E DISCUSSÃO	34
1.4.1 REVISÃO BIBLIOMÉTRICA	34
1.5 CONSIDERAÇÕES DO CAPÍTULO	60
REFERÊNCIAS	61
CAPÍTULO 2	69
YOLOV8 PARA A IDENTIFICAÇÃO DE MADEIRAS TROPICAIS POR MEIO DE IMAGENS MACROSCÓPICAS	69
2.1 INTRODUÇÃO	71
2.2 OBJETIVOS	72
2.2.1 Objetivo geral	72
2.2.2 Objetivos específicos	72
2.3 REVISÃO DE LITERATURA	73
2.3.1 IDENTIFICAÇÃO DE MADEIRAS E ANÁLISE DE IMAGENS	73
2.4 METODOLOGIA	77
2.4.1.1 Banco de dados 1 – Caatinga (autoria própria)	77
2.4.1.2 Banco de dados 2 – Mata Atlântica (ANDRADE; BASSO; LATORRACA, 2020)	80
2.4.1.3 Banco de dados 3 – Miscelânea (PAULA FILHO et al., 2014; SOUZA et al., 2020; <i>Dataset</i> Polícia Federal)	82

1) <i>Forest Species Database – Macroscopic (FSD-M)</i> (PAULA FILHO et al., 2014).....	82
2) <i>Endangered Forest Species</i> (SOUZA et al., 2020)	84
3) PF e Combinação miscelânea	86
2.4.2 VISÃO COMPUTACIONAL	88
2.4.2.1 Preparação dos Dados - Pré-processamento.....	90
2.4.2.2 Treinamento, validação, teste e análises de métricas	91
2.5 RESULTADOS E DISCUSSÃO	94
2.5.1 TESTE 1- BANCO DE DADOS CAATINGA	94
2.5.2 TESTE 2 - BANCO DE DADOS MATA ATLÂNTICA	99
2.5.3 TESTE 3 - BANCO DE DADOS CAATINGA + MATA ATLÂNTICA	106
2.5.4 TESTE 4 BANCO DE DADOS CAATINGA + MATA ATLÂNTICA + FSD-M + EFS+PF	110
2.6 CONSIDERAÇÕES DO CAPÍTULO	122
REFERÊNCIAS	124
CONSIDERAÇÕES FINAIS	128
REFERÊNCIAS GERAIS	130
ANEXO I	142

INTRODUÇÃO GERAL

O *Machine Learning*, ou Aprendizado de Máquina, é uma área da inteligência artificial que se concentra no desenvolvimento de algoritmos e modelos capazes de aprender padrões e realizar tarefas específicas sem a necessidade de programação explícita. Existem diversos tipos de abordagens de aprendizado de máquina, incluindo aprendizado supervisionado, não supervisionado e por reforço. No aprendizado supervisionado os modelos são treinados com exemplos rotulados, enquanto no aprendizado não supervisionado os modelos exploram padrões em conjuntos de dados não rotulados. Já o aprendizado por reforço envolve a interação do modelo com um ambiente dinâmico, aprendendo através de tentativa e erro. As principais técnicas de aprendizado de máquina incluem regressão, classificação, *clustering* e redes neurais.

As Redes Neurais Artificiais (RNAs) são uma classe de modelos computacionais inspirados no funcionamento do sistema nervoso humano (por isso a denominação “redes neurais”), capazes de aprender a partir de dados e realizar tarefas complexas de forma automatizada. Entre as diversas arquiteturas de RNAs, as Redes Neurais Convolucionais (RNCs) se destacam pela capacidade de processar e analisar dados em formato de grade, como imagens, de forma eficiente e robusta. Essas redes são compostas por camadas convolucionais, que aplicam filtros convolucionais para extrair características relevantes dos dados de entrada, seguidas por camadas de *pooling*, que reduzem a dimensionalidade dos dados, e camadas totalmente conectadas, responsáveis pela classificação ou regressão final. O uso de RNCs tem sido amplamente explorado em diversas aplicações, como reconhecimento de imagens, processamento de linguagem natural e análise de vídeos, destacando-se tarefas de classificação e detecção. Estudos como o de LeCun et al. (1998), Krizhevsky et al. (2012) e Simonyan e Zisserman (2015) demonstraram o potencial das RNCs em alcançar resultados de alta precisão e eficiência em tarefas de classificação de imagens, impulsionando avanços significativos em áreas como visão computacional e reconhecimento de padrões.

O uso de técnicas de *Machine Learning* na Engenharia Florestal tem se mostrado promissor para melhorar a gestão de recursos naturais e a tomada de

decisões em atividades florestais, destacando o potencial destas técnicas para auxiliar na conservação e manejo sustentável das florestas. Diversos trabalhos investigaram o uso de algoritmos de aprendizado de máquina para identificar desmatamento, otimizar estratégias de manejo florestal, prever e identificar riscos de incêndios florestais e tantas outras aplicações, muitas delas aliadas às geotecnologias (Briechle et al., 2021; Huang et al., 2023; Kattenborn et al., 2021; Liu et al., 2020; Silva et al., 2022a; Wang et al., 2023; Zhang et al., 2022; Zhao et al., 2023).

Na Tecnologia da Madeira, o uso de técnicas de *Machine Learning* tem sido utilizado especialmente para melhorar a eficiência dos processos de produção e o controle de qualidade dos produtos. Destacam-se os trabalhos de detecção de defeitos (Fan et al., 2019; Sun, 2022; Urbonas et al., 2019; Yang et al., 2022;) e para a predição de propriedades da madeira (Chen et al., 2023; Nasir et al., 2021; Neyses, Scharf, 2022; Schubert, Kläusler, 2020) como propriedades físicas e mecânicas da madeira, com base em características como densidade e umidade, além de diversos estudos sobre o entendimento e otimização de processos de secagem (Blokland et al., 2021; Rahimi et al., 2023; Rahimi; Avramidis, 2022).

A aplicação de técnicas de *Machine Learning* na identificação de madeiras tem sido objeto de pesquisa devido à sua relevância em diversas indústrias, como a de móveis e construção (Hwang; Sugiyama, 2021; Silva et al., 2022b). Ravidran et al. (2022), Ravindran et al. (2021) e Lens et al. (2020) exemplificam alguns dos avanços nesta temática ao investigar a utilização de modelos para classificar diferentes espécies de madeira com base em características visuais e estruturais. Portanto, diversos métodos, especialmente de processamento e classificação têm sido explorados para automatizar e aprimorar os processos de identificação de madeira, aliando visão computacional e aprendizado de máquina, baseando-se especialmente na identificação de texturas e padrões (Hwang; Sugiyama, 2021).

No entanto, apesar das vantagens evidentes dessas técnicas, como automação e rapidez, também existem desafios significativos. A interpretação correta das características visuais da madeira pode ser dificultada pela presença de variações naturais e condições ambientais. Ademais, a disponibilidade e

qualidade dos conjuntos de dados de treinamento podem afetar a capacidade dos modelos de generalizar para diferentes contextos (Silva et al., 2022b).

Outro aspecto a ser considerado é a necessidade de *expertise* na construção e avaliação dos modelos de identificação de madeira pois a falta de conhecimento especializado pode levar a erros de classificação e comprometer a confiabilidade dos sistemas automáticos de identificação de madeira. Portanto, embora as técnicas computacionais, incluindo visão computacional e aprendizado de máquina, ofereçam oportunidades promissoras para a identificação automatizada de madeiras, é essencial investigar e compreender os desafios existentes.

OBJETIVOS

Objetivo geral

Compreender o estado da arte sobre a identificação/distinção de madeiras utilizando imagens macroscópicas e inteligência artificial, além de testar a eficiência do *software* YOLO (*You Only Look Once*) para a identificação/distinção de madeiras utilizando diferentes bancos de dados.

Objetivos específicos

- Realizar revisão bibliométrica e construir o estado da arte sobre a identificação/distinção de madeiras utilizando imagens macroscópicas e inteligência artificial;
- Construir um banco de imagens macroscópicas de madeiras de 7 espécies da Caatinga utilizando imagens obtidas por câmera de celular;
- Testar a eficiência do YOLO v8 para a identificação/distinção de madeiras dos biomas Caatinga, Mata Atlântica e Amazônia assim como de algumas espécies exóticas de interesse comercial como pinus, eucalipto, cinamomo e grevílea a partir de imagens de bancos de dados distintos.

ESTRUTURA DA DISSERTAÇÃO

Este trabalho está dividido em 2 capítulos, sendo resumidos a seguir.

Capítulo 1 – Este capítulo apresenta uma revisão bibliométrica e o estado da arte sobre o uso de imagens e inteligência artificial na identificação/distinção de madeiras de acordo com artigos científicos indexados na plataforma *Scopus*, destacando em resumo os autores, países e instituições que possuem o maior número de publicações na área.

Capítulo 2 – A parte inicial do capítulo mostra a construção de banco de dados de imagens de 7 espécies da Caatinga, e posteriormente a construção de modelos e processamento de 5 bancos de dados distintos de imagens utilizando YOLOv8m-cls. São avaliados e discutidos os principais parâmetros que mostram a acurácia e precisão dos modelos, bem como a matriz de confusão em cada caso, indicando ou não a possibilidade de aplicação da técnica na distinção da madeira de espécies florestais com base na análise de imagens macroscópicas.

REFERÊNCIAS

BLOKLAND, J.; NASIR, V.; COOL, J.; AVRAMIDIS, S.; ADAMOPOULOS, S. Machine learning-based prediction of internal checks in weathered thermally modified timber. **Construction and Building Materials**, v. 281, p. 122193, 2021.

BRIECHLE, S.; KRZYSTEK, P.; VOSSELMAN, G. Silvi-Net—A dual-CNN approach for combined classification of tree species and standing dead trees from remote sensing data. **International Journal of Applied Earth Observation and Geoinformation**, v. 98, p. 102292, 2021.

CHEN, S.; SHIINA, R.; NAKAI, K.; AWANO, T.; YOSHINAGA, A.; SUGIYAMA, J. Potential of machine learning approaches for predicting mechanical properties of spruce wood in the transverse direction. **Journal of Wood Science**, v. 69, n. 1, p. 22, 2023.

FAN, J.; LIU, Y.; HU, Z. K.; ZHAO, Q.; SHEN, L. X.; ZHOU, X. L. Solid wood panel defect detection and recognition system based on faster R-CNN. **Journal of Forestry Engineering**, v. 4, n. 3, p. 112-117, 2019.

HUANG, J.; HE, J.; GUAN, Y.; ZHANG, H. Real-time forest fire detection by ensemble lightweight YOLOX-L and defogging method. **Sensors**, v. 23, n. 4, p. 1894, 2023.

HWANG, S.; 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, 2021.

KATTENBORN, T.; LEITLOFF, J.; SCHIEFER, F.; HINZ, S. Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. **ISPRS journal of photogrammetry and remote sensing**, v. 173, p. 24-49, 2021.

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

LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, p. 2278-2324, 1998.

LENS, F.; LIANG, C.; GUO, Y.; TANG, X.; JAHANBANIFARD, M.; da SILVA, F. S. C.; CECCANTINI, G.; VERBEEK, F. J. Computer-assisted timber identification based on features extracted from microscopic wood sections. **IAWA Journal**, v. 41, n. 4, p. 660-680, 2020.

LIU, Z.; ZHANG, K.; WANG, C.; HUANG, S. Research on the identification method for the forest fire based on deep learning. **Optik**, v. 223, p. 165491, 2020.

NASIR, V.; FATHI, H.; FALLAH, A.; KAZERIMAD, S.; SASSANI, F.; ANTOV, P. Prediction of mechanical properties of artificially weathered wood by color change and machine learning. **Materials**, v. 14, n. 21, p. 6314, 2021.

NEYSES, B.; SCHARF, A. Using machine learning to predict the density profiles of surface-densified wood based on cross-sectional images. **European Journal of Wood and Wood Products**, v. 80, n. 5, p. 1121-1133, 2022.

RAHIMI, S.; NASIR, V.; AVRAMIDIS, S.; SASSANI, F. The role of drying schedule and conditioning in moisture uniformity in wood: A machine learning approach. **Polymers**, v. 15, n. 4, p. 792, 2023.

RAHIMI, S.; AVRAMIDIS, S. Predicting moisture content in kiln dried timbers using machine learning. **European Journal of Wood and Wood Products**, v. 80, n. 3, p. 681-692, 2022.

RAVINDRAN, P.; OWENS, F. C.; WADE, A. C.; VEGA, P.; MONTENEGRO, R.; WIEDENHOEFT, A. C. Field-deployable computer vision wood identification of Peruvian timbers. **Frontiers in Plant Science**, v. 12, p. 647515, 2021.

RAVINDRAN, P.; OWENS, F. C.; WADE, A. C.; SHMULSKY, R.; WIEDENHOEFT, A. C. Towards sustainable North American wood product value chains, part I: Computer vision identification of diffuse porous hardwoods. **Frontiers in Plant Science**, v. 12, p. 758455, 2022.

SCHUBERT, M.; KLÄUSLER, O. Applying machine learning to predict the tensile shear strength of bonded beech wood as a function of the composition of polyurethane prepolymers and various pretreatments. **Wood Science and Technology**, v. 54, n. 1, p. 19-29, 2020.

SILVA, C. A.; GUERRISI, G.; DEL FRATE, F.; SANO, E. E. Near-real time deforestation detection in the Brazilian Amazon with Sentinel-1 and neural networks. **European Journal of Remote Sensing**, 55:1, 129-149, 2022a.

SILVA, J. L.; BORDALO, R.; PISSARA, J.; PALACIOS, P. Computer vision-based wood identification: A review. **Forests**, v. 13, n. 12, p. 2041, 2022b.

SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. **Proceedings of the ICLR 2015**, p. 1-14, 2015.

SUN, P. Wood quality defect detection based on deep learning and multicriteria framework. **Mathematical Problems in Engineering**, v. 2022, p. 1-9, 2022.

URBONAS, A.; RAUDONIS, V.; MASKELIŪNAS, R.; DAMAŠEVIČIUS, R. Automated identification of wood veneer surface defects using faster region-based convolutional neural network with data augmentation and transfer learning. **Applied Sciences**, v. 9, n. 22, p. 4898, 2019.

WANG, Z.; LI, P.; CUI, Y.; LEI, S.; JANG, Z. Automatic detection of individual trees in forests based on airborne LiDAR data with a tree region-based

convolutional neural network (RCNN). **Remote Sensing**, v. 15, n. 4, p. 1024, 2023.

YANG, Y.; ZHOU, X.; LIU, Y.; HU, Z.; DING, F. Wood defect detection based on depth extreme learning machine. **Applied Sciences**, v. 10, n. 21, p. 7488, 2022.

ZHANG, C.; ZHOU, J. WANG, H.; TAN, T.; CUI, M.; HUANG, Z.; WANG, P.; ZHANG, L. Multi-species individual tree segmentation and identification based on improved mask R-CNN and UAV imagery in mixed forests. **Remote Sensing**, v. 14, n. 4, p. 874, 2022.

ZHAO, H.; MORGENRHOT, J.; PEARSE, G.; SCHINDLER, J. A systematic review of individual tree crown detection and delineation with convolutional neural networks (CNN). **Current Forestry Reports**, v. 9, n. 3, p. 149-170, 2023.

CAPÍTULO 1

PANORAMA DO USO DE IMAGENS E INTELIGÊNCIA ARTIFICIAL NA IDENTIFICAÇÃO E DISTINÇÃO DE MADEIRAS

RESUMO

Nas últimas décadas o uso de imagens em conjunto com técnicas computacionais tem sido estudado para a identificação e distinção de madeiras. Os esforços mais recentes têm se concentrado no uso de redes neurais artificiais, aprendizado profundo e visão computacional para tarefas de classificação. Para compreensão desse cenário, uma revisão bibliométrica foi realizada utilizando uma combinação de várias palavras-chave relacionadas à identificação de madeiras e identificação por visão computacional na plataforma *Scopus*, focando-se apenas em artigos científicos. Após a triagem, um total de 44 artigos foram analisados e o estado da arte deste tema construído. Neste universo, destacam-se como os principais produtores de conhecimento o Brasil e Estados Unidos, demonstrando a relevância não só pelo quantitativo de espécies comercializadas, mas também no desenvolvimento de técnicas e tecnologia. Além disso, destaca-se o uso de redes neurais convolucionais em diferentes configurações.

Palavras-chave: revisão bibliométrica; aprendizado de máquina; visão computacional; identificação de espécies madeiras

A PANORAMA OF IMAGE AND ARTIFICIAL INTELLIGENCE USE IN WOOD DISTINCTION AND IDENTIFICATION

ABSTRACT

In recent decades, the use of images in association with computational techniques has been studied for the identification and distinction of wood. The most recent efforts have focused on the use of artificial neural networks, deep learning and computer vision for classification tasks. To understand this scenario, a bibliometric review was carried out using a combination of various keywords related to wood identification and computer vision identification on the Scopus platform, focusing only on scientific articles. After screening, a total of 44 articles were analyzed and the state of the art of this topic was constructed. In this universe, Brazil and the United States stand out as the main producers of knowledge, demonstrating their relevance not only in terms of the number of species traded, but also in the development of techniques and technology. In addition, the use of convolutional neural networks in different configurations stands out.

Keywords: bibliometric review; machine learning; computer vision; timber species identification

1.1 INTRODUÇÃO

A identificação tradicional de madeiras é um processo complexo que envolve a análise de diversas características morfológicas e anatômicas das amostras, como textura, cor, grã, tipo de vasos e parênquima, porosidade, etc. Este método, geralmente, requer especialistas com vasta experiência e treinamento na área, devido à necessidade de distinguir entre uma grande variedade de espécies de madeira. No entanto, apesar da eficácia desses especialistas, a identificação manual de madeiras enfrenta desafios significativos, incluindo a subjetividade na interpretação das características das amostras, tempo e custos para o preparo da amostra, destruição da amostra e a falta de pessoal especializado para atender a demanda. Além disso, o número limitado de especialistas disponíveis e o alto custo associado ao treinamento e à manutenção de uma equipe de identificação tradicional, representam desvantagens consideráveis para esse método.

Técnicas não destrutivas, como a espectroscopia de infravermelho próximo (NIR) e a análise de imagem por ressonância magnética (MRI), têm sido exploradas como alternativas para a identificação de madeiras. No entanto, essas técnicas enfrentam desafios, como a necessidade de equipamentos sofisticados e a complexidade na interpretação dos resultados.

A aplicação de inteligência artificial (IA) na engenharia florestal tem se mostrado uma área promissora devido à sua capacidade de automatizar processos e tomar decisões com base em dados. Nos últimos anos, seu uso tem se expandido, abrangendo diversas aplicações, como previsão de crescimento de árvores, detecção de doenças florestais e monitoramento de desmatamento. A IA tem sido utilizada para analisar grandes conjuntos de dados e extrair padrões relevantes, fornecendo *insights* valiosos para a gestão sustentável dos recursos florestais.

A utilização de imagens e inteligência artificial na identificação e distinção de madeiras tem sido objeto de crescente interesse na comunidade acadêmica e na indústria, devido à sua relevância em áreas como controle de qualidade, preservação ambiental e combate ao comércio ilegal de madeira. Estudos recentes exploraram uma variedade de técnicas e abordagens para automatizar e aprimorar esse processo complexo (Hwang; Sugiyama, 2021; Silva et al.,

2022). Uma das abordagens mais comuns é a aplicação de redes neurais convolucionais (RNCs). Essas redes são capazes de extrair características únicas das imagens de madeira, permitindo a classificação precisa e eficiente das espécies. Além disso, técnicas de processamento de imagem, como a análise de textura e a segmentação de regiões de interesse, têm sido amplamente exploradas.

A aplicação de algoritmos de aprendizado de máquina, como máquinas de vetores de suporte (SVM) e redes neurais artificiais (RNAs), também tem sido investigada para identificar padrões em imagens de madeira e sua eficácia é reportada na literatura (Sugiarto et al., 2020; Turhan; Serdar, 2013;). Além disso, abordagens baseadas em aprendizado por transferência (*transfer learning*), onde modelos pré-treinados são adaptados para tarefas específicas de identificação de madeira, têm ganhado destaque (Hwang; Sugiyama, 2021).

Para compreender como está o cenário da identificação de madeiras a partir de imagens e inteligência artificial é importante realizar uma revisão sobre o tema, destacando-se o papel de uma revisão bibliométrica para uma compreensão do estado da arte em qualquer temática. Uma revisão bibliométrica é uma análise quantitativa e qualitativa da produção científica em um determinado campo, que permite identificar tendências, padrões e lacunas de pesquisa (Moed, 2009). Os principais pontos de uma revisão bibliométrica incluem a coleta e análise de dados bibliográficos, como número de publicações, autores mais citados, instituições líderes e temas mais explorados (Martín-Martín et al., 2018). Este tipo de revisão é essencial para entender o estado atual do conhecimento em uma área específica, identificar áreas de interesse emergentes e direcionar futuras pesquisas.

Geralmente as pesquisas bibliométricas se iniciam nas plataformas de buscas, destacando-se a plataforma *Scopus*, desenvolvida pela Elsevier, que oferece acesso a uma vasta coleção de literatura científica revisada por pares. Lançada em 2004, a *Scopus* tornou-se uma das maiores e mais abrangentes bases de dados bibliográficos do mundo, cobrindo uma ampla gama de disciplinas acadêmicas em obras de diversos formatos (artigos científicos, conferências, livros e patentes) (Falagas et al., 2008). A plataforma oferece recursos avançados de busca, análise de citações, métricas de pesquisa e colaboração acadêmica, tornando-se uma ferramenta indispensável para

pesquisadores, instituições acadêmicas e profissionais da área científica (Kulkarni et al., 2009).

1.2 OBJETIVOS

1.2.1 Objetivo geral

Realizar uma revisão bibliométrica para compreender o estado da arte do uso da inteligência artificial para a identificação de madeiras a partir de imagens.

1.2.2 Objetivos específicos

- Identificar os principais autores, publicações, periódicos, países que mais publicam e principais palavras-chave utilizadas;
- Identificar os principais equipamentos de obtenção de imagem;
- Elencar as principais técnicas de IA utilizadas na identificação de madeira;
- Identificar tendências na área para nortear trabalhos futuros.

1.3 METODOLOGIA

Visando uma maior compreensão sobre a identificação de madeiras utilizando imagens e inteligência artificial, foi realizada uma análise de todas as publicações indexadas na base de dados *Scopus* até o ano 2022, seguindo a metodologia proposta por Silva et al. (2020). Ressalta-se que uma revisão bibliométrica realizada a partir de um banco de dados da *Scopus* não abrange todos os trabalhos publicados sobre o tema, no entanto, a base foi escolhida por estar em constante aprimoramento e apresentar grande alcance e impacto no meio científico, sendo utilizada amplamente por diversos especialistas e estudos bibliométricos (Gasparyan et al., 2011; Khudzari et al., 2018; Patro; Misra, 2020).

Portanto, apesar do banco de dados gerado na *Scopus* não apresentar um censo das publicações sobre o assunto, ele pode ser considerado como uma amostragem representativa uma vez que na plataforma existem trabalhos de revistas científicas, livros e trabalhos de conferências indexados com grande alcance no meio científico. Além das referências em si (título, autores, resumo e palavras-chave), a *Scopus* fornece inúmeras métricas que podem ser utilizadas para análises estatísticas em *softwares* especializados. Por fim, a *Scopus* possui significativa relevância no Brasil já que parte das métricas geradas na plataforma são utilizadas como componente da avaliação de cursos de graduação e pós-graduação (Montoya et al., 2018).

A busca na plataforma *Scopus* foi realizada por meio de uma combinação de termos em inglês sobre o assunto com o objetivo de contemplar um maior banco de dados já que o inglês é língua predominante nos periódicos científicos. No caso de periódicos não anglófonos, mesmo que o texto principal não esteja em inglês, há um predomínio da presença do resumo e palavras-chave (*abstract* e *keywords*) também em inglês. Ademais, mesmo em publicações em outros idiomas, é predominante o uso dos termos da área de informática e tecnologia em geral em inglês. Para a realização da busca em títulos, resumos e palavras-chave foram utilizados os termos “*forest specie**”, “*wood* recognition*”, “*wood* identification*”, “*wood* anatomy*”, “*machine learning*”, “*artificial intelligence*”, “*deep learning*”, “*computer vision-based*”, “*automatic classification*”, “*machine vision*”, “*pattern recognition*”, “*image* identification*”.

A sequência utilizada na pesquisa foi: (TITLE-ABS-KEY ("forest specie*" OR "wood* recognition" OR "wood* discrimination" OR "wood* identification" OR "wood* specie*" OR "wood* anatomy") AND TITLE-ABS-KEY ("machine learning" OR "artificial intelligence" OR "deep learning" OR "computer vision-based" OR "automatic classification" OR "machine vision" OR "pattern*recognition" OR "image* identification")) AND PUBYEAR > 1990 AND PUBYEAR < 2023. O ano de 2023 não foi incluído pois estava em curso quando da realização da busca, o que poderia subestimar os resultados já que outras publicações poderiam ocorrer no ano de 2023 após a realização da busca. Inicialmente o intuito era focar em estudos sobre identificação de madeiras utilizando imagens e inteligência artificial realizados no Brasil, mas isso restringiria em demasia os resultados.

A partir desses parâmetros foram encontradas 206 publicações, que foram acessadas e lidas integralmente quando disponíveis (em caso contrário, as informações foram extraídas do título, resumo e palavras-chave). As publicações foram submetidas a uma triagem para selecionar apenas aquelas relacionadas à identificação de madeiras utilizando imagens e inteligência artificial. Os critérios de seleção pré-estabelecidos foram: 1. uso de imagens para a identificação de madeiras, 2. uso de técnicas de inteligência artificial, 3. pertencer à área de tecnologia da madeira; 4. realizaram identificação/distinção de madeiras; 5. as publicações serem artigos científicos. Apenas as publicações que atenderam a todos os critérios supracitados passaram para a próxima etapa de análise.

Após a exclusão de duplicatas, foram elencados os trabalhos que atenderam simultaneamente os critérios supracitados e coletadas as seguintes informações: (a) principais palavras presentes nos títulos dos trabalhos; (b) identificação dos autores e respectivas instituições de afiliação; (c) rede de clusters de interligação entre os autores, utilizando o programa VOSviewer versão 1.6.15; (d) agências e instituições de fomento dos trabalhos; (e) ano de publicação; (f) periódicos das publicações. Esses dados foram tabulados para confecção dos gráficos para cada parâmetro no programa computacional R (R Core Team, 2023), utilizando *Biblioshiny* e *Bibliometrix* (Aria; Cuccurullo, 2017).

Para a elaboração do estado da arte, os documentos que atenderam aos critérios de inclusão, foram mapeados para uma maior compreensão do tema

pesquisado elencando-se: (a) país do estudo; (b) quantidade de espécies estudadas; (c) preparo da superfície da amostra; (d) tipo de imagem; (e) face fotografada; (f) tipo de equipamento utilizado para a aquisição de imagem; (g) *zoom*; (h) resolução da imagem; (i) algoritmos e técnicas utilizados no processamento e pré-processamento; (j) tamanho do banco de dados; (k) divisão do banco de dados (treinamento, validação, teste); (l) métricas de acerto (acurácia, f1, percentual de acerto).

Durante a análise do banco de dados foram excluídos trabalhos: que se utilizam de caracteres quantitativos não extraídos de imagens; trabalhos que não geraram novos resultados ou que compilaram resultados/dados de outros autores (independentemente de estar dentro do tema e contemplarem os critérios de inclusão); trabalhos classificados como “*conference paper*” e trabalhos que apenas descrevem a criação de *dataset* ou *software/aplicativo/aparato* para obtenção de imagens.

1.4 RESULTADOS E DISCUSSÃO


Após a triagem, apenas 44 trabalhos atenderam os critérios de inclusão, sendo excluídos, portanto, 162 trabalhos, dos quais 91 são Tecnologia da Madeira e os 71 restantes são, majoritariamente, da área de Manejo. Não foi possível acessar o trabalho intitulado “*Identification of north american softwoods via machine-learning*”, mesmo após solicitar via e-mail para os autores assim como via *Research Gate*. Como as informações contidas no resumo deste trabalho não foram suficientes para determinar se atendia aos dois primeiros critérios de inclusão, ele foi excluído da análise.

1.4.1 REVISÃO BIBLIOMÉTRICA

a) Autores e instituições

As publicações totalizam 159 autores, destacando-se Ravindran e Wiedenhoefft como os autores que possuem o maior número de publicações (7), sendo co-autores em 6 trabalhos, seguidos por Sugiyama (5), e Hwang e Kobayashi (ambos com 4 publicações) (Figura 1).

FIGURA 1 – NÚMERO DE DOCUMENTOS POR AUTOR (TOP 10)

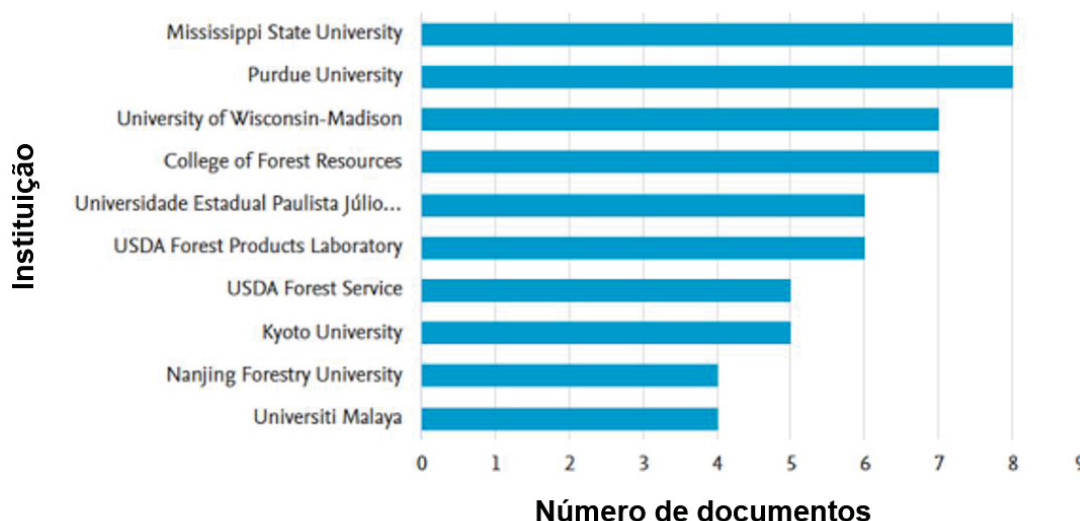


FONTE: A autora (2024).

A maior parte dos autores estava afiliada a instituições americanas (3), destacando-se a *Mississippi State University* (Universidade Estadual do

Mississippi), aonde fica localizado o *College of Forest Resources* (Figura 2), totalizando 15 trabalhos. Neste ínterim é interessante destacar o protagonismo de universidades como produtoras de ciência já que apenas uma das instituições listadas no *top 10* não é uma instituição de ensino e sim uma agência nacional florestal (*USDA Forest Service*, instituição que abriga os *USDA Forest Products Laboratories*), pertencente ao governo estadunidense, que concentra 11 trabalhos. Nesta lista, 6 instituições/laboratórios/departamentos são estadunidenses, uma japonesa (*Kyoto University*), uma chinesa (*Nanjing Forestry University*) e uma malaia (*Universiti Malaya*). Por fim, o Brasil é representado apenas pela Universidade Estadual Paulista, localizada no estado de São Paulo, na região sudeste do país.

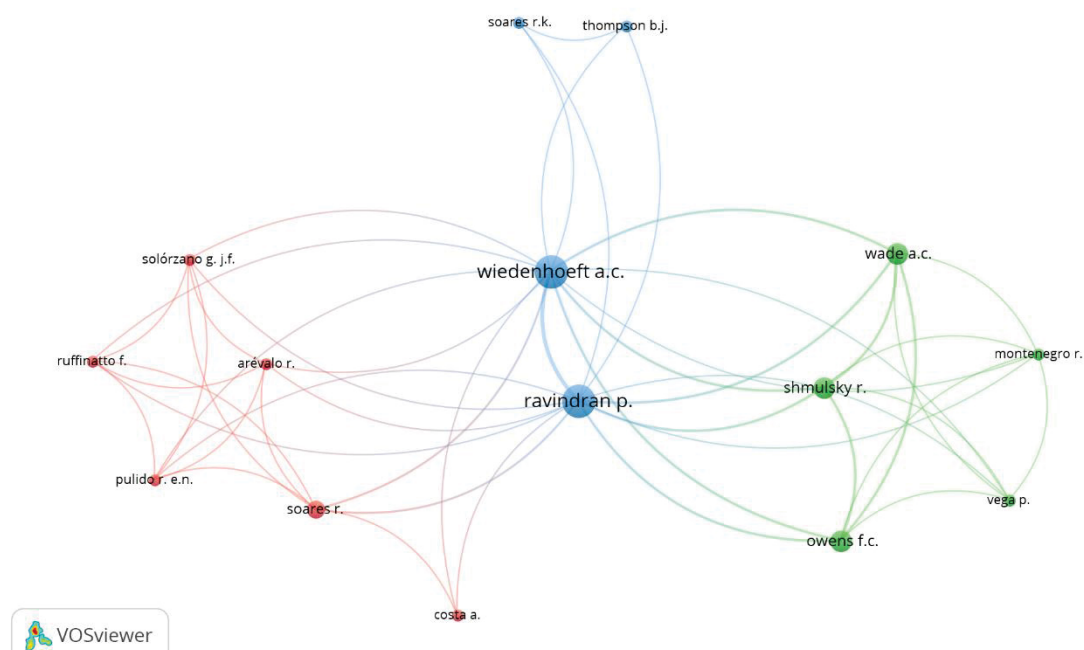
FIGURA 2 – RELAÇÃO DAS PRINCIPAIS INSTITUIÇÕES DE AFILIAÇÃO DOS AUTORES (TOP 10)



FONTE: A autora (2024).

A principal rede de interligação dos autores (Figura 3) apresenta como principais colaboradores Ravindran e Wiedenhoef, autores que apresentam o maior número de interligações, se conectando a todos os autores da rede, o que indica um elevado grau de cooperação entre esses autores e os *clusters* “secundários”.


FIGURA 3 – PRINCIPAL REDE DE CLUSTERS DE INTERLIGAÇÃO ENTRE OS AUTORES



FONTE: A autora (2024).

Essa cooperação entre autores ultrapassa fronteiras nacionais, com a principal colaboração entre Estados Unidos da América e Brasil, seguido de China e Japão (Figura 4). A colaboração entre autores, instituições e países são ótimas oportunidades para troca de conhecimento, fortalecimento de relações sociais, tecnológicas e econômicas, sendo muitas vezes de suma importância para o desenvolvimento tecnológico dos setores de interesse.


FIGURA 4 – MAPA DE COLABORAÇÃO ENTRE PAÍSES



FONTE: A autora (2024).'

Dois brasileiros estão entre os autores dos *top 5* trabalhos mais citados sobre a temática, sendo Martins et al. (2013) também a referência mais numerosa de todos os trabalhos, provavelmente considerada como referência no assunto (Figura 5). Esse artigo é fruto de uma parceria entre a Universidade Federal do Paraná (UFPR, Paraná, Brasil) e a *Ecole de Technologie Superieure* (Canadá). A segunda brasileira é Rosa da Silva et al. (2017), primeira autora de um trabalho fruto de parceria entre a Universidade Federal de Catalão (Goiás, Brasil), Universidade de São Paulo (USP, São Paulo, Brasil), *Ghent University* (Bélgica) e *Royal Museum for Central Africa* (Bélgica).

FIGURA 5 – TRABALHOS MAIS CITADOS (TOP 10)




FONTE: A autora (2024).

b) Agências e instituições de fomento dos trabalhos

As principais agências de fomento são dos Estados Unidos e Japão, com o Brasil sendo representado por 3 instituições (CAPES, CNPq e FAPESP), destacando-se nesse cenário a importância do investimento público em pesquisas científicas para o avanço da ciência e tecnologia no país (Figura 6).

FIGURA 6 – NÚMERO DE DOCUMENTOS POR AGÊNCIA DE FOMENTO




FONTE: A autora (2024).

c) Ano de publicação

Os trabalhos foram publicados entre os anos de 2011 a 2022, em que o maior número de publicações (11) ocorrendo no ano de 2021, e com o segundo maior pico em 2013 (5) (Figura 7). No gráfico, o número de publicações é zero nos anos de 2012 e 2014, o que não necessariamente indica que não houve nenhuma publicação de nenhuma natureza a respeito da temática, apenas nenhuma indexada pela *Scopus* que atendessem aos critérios estabelecidos neste estudo. É possível observar que desde 2014 o interesse pela temática é crescente, sendo provavelmente um reflexo dos avanços tecnológicos, maior acesso às tecnologias associadas e informações a respeito do tema.

FIGURA 7 – QUANTIDADE DE ARTIGOS PUBLICADOS POR ANO




FONTE: A autora (2024).

d) Periódicos

Como o esperado, a maior parte das publicações se concentram nas áreas das Ciências Agrárias (30,1%) e Ciência da Computação (16,9%), destacando-se também a área de Ciência dos Materiais (14,5%) (Figura 8).

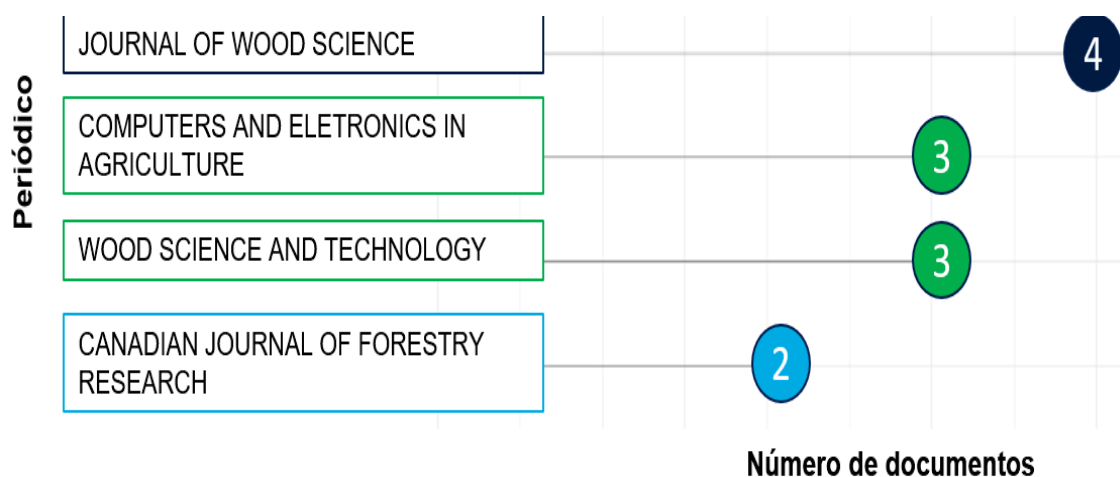
FIGURA 8 – DOCUMENTOS POR ÁREA DE CONHECIMENTO



FONTE: A autora (2024).

Destaca-se o número de periódicos especializados na área de Ciências Agrárias e Engenharia Florestal, sendo essa a área que domina o *top 5* de periódicos com mais publicações (Figura 9). Os periódicos que concentram o maior número de publicações são “*Frontiers in Plant Science*” e “*Journal of Wood Science*”. Saber onde os estudos sobre essa temática mais são publicados é uma informação de grande valia para direcionar a publicação de trabalhos futuros, potencialmente poupando o tempo dos autores na busca por um periódico adequado e podendo inclusive antecipar o direcionamento da escrita do artigo de maneira mais adequada ao escopo e objetivos da revista almejada.

FIGURA 9 – PRINCIPAIS PERIÓDICOS (TOP 5)




FONTE: A autora (2024).

e) Palavras-chave

As principais palavras-chave são “*wood identification*” (16), “*deep learning*” (12), “*computer vision*” (10) e “*machine learning*” (10) (Figura 10). Há uma predominância de termos da área de tecnologia/informática para essa temática, mantendo-se a dicotomia com Ciências Agrárias já que este é um tema que atravessa as duas áreas do conhecimento. É interessante notar que também integram o *top 15* “*illegal logging and timber trade*” e “*CITES*”, indicando que ao menos parte destes trabalhos provavelmente tem um foco no uso/desenvolvimento de técnicas visando a melhora na fiscalização da movimentação e comercialização de madeiras, especialmente no âmbito global tratando-se da sigla “*CITES*”.

A *Convention on International Trade in Endangered Species of Wild Fauna and Flora* (CITES - Convenção sobre o Comércio Internacional de Espécies Ameaçadas de Fauna e Flora Selvagens) é um acordo internacional entre governos que tem como objetivo “garantir que o comércio internacional de espécimes de animais e plantas selvagens não ameace a sobrevivência das espécies” (CITES, 2024). Este acordo é um instrumento de referência internacional instituído pela IUCN (*The World Conservation Union*, União Internacional para a Conservação da Natureza) endossado por 184 membros (Estados e blocos econômicos) (CITES, 2024). Portanto, a inclusão de CITES como palavra-chave indica a relevância e compromisso desse acordo, inclusive como uma das forças propulsoras para esforços conservacionistas aliando conhecimentos tradicionais e novas tecnologias para agilizar e facilitar a identificação de espécies.

FIGURA 10 – TOP 15 PALAVRAS-CHAVE MAIS RELEVANTES (AUTORES)

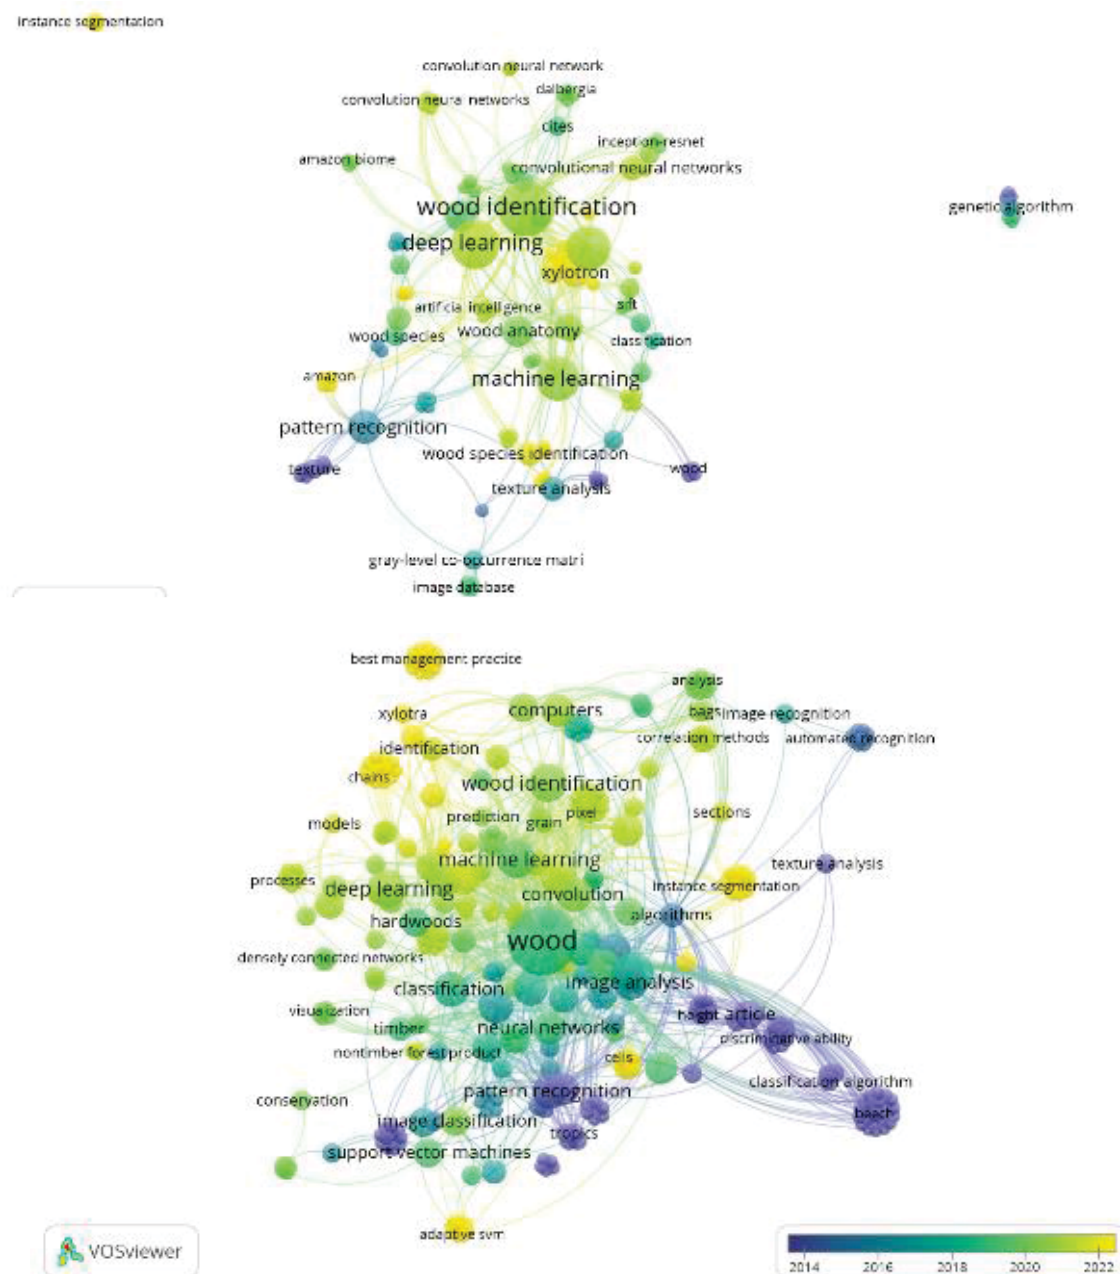


FONTE: A autora (2024).

A escolha correta de palavras-chave demonstra o conhecimento dos autores em relação ao tema, mas também é essencial para facilitar a entrega do artigo ao público-alvo correto nos mecanismos de busca, além de correta indexação nas plataformas. Ou seja, o uso correto de palavras-chave é um dos fatores determinantes para a visibilidade e alcance de um artigo. Além da área do conhecimento, há uma correlação temporal das palavras, sendo possível compreender tendências e correlações, como pode ser observado nas redes de

palavras-chave determinadas pelos autores e indexadas pela plataforma (Figura 11). A partir dessa rede é possível identificar um vislumbre do panorama da temática.

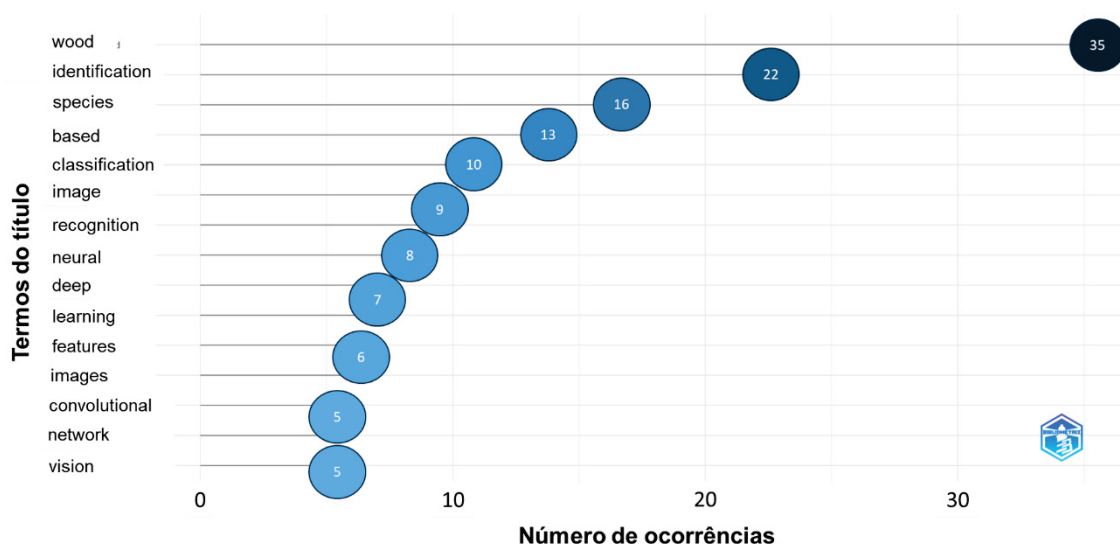
FIGURA 11 – REDE DE CONEXÕES ENTRE PALAVRAS-CHAVE



FONTE: A autora (2024).

A mesma argumentação é válida para a escolha das palavras que irão formar o título e, sendo o primeiro item do trabalho que o leitor terá contato, ele é significativo não só para sua alocação nos resultados de busca, mas também aumenta as chances de o artigo ser lido pelo público de interesse. Para o título, os autores escolheram majoritariamente termos da área de computação, sendo a área de Ciências Agrárias representada apenas por dois termos (“*wood*” e “*species*”) (Figura 12). Isto pode indicar, ao menos em um primeiro momento, que o foco dos trabalhos presentes neste banco de dados é no desenvolvimento, aprimoramento ou comparação de técnicas, tecnologias e metodologias computacionais para a identificação/distinção de espécies.

FIGURA 12 – TOP 15 TERMOS MAIS RELEVANTES PARA O TÍTULO



FONTE: A autora (2024).

1.4.2. ESTADO DA ARTE

Após a triagem inicial dos estudos, uma análise mais aprofundada de cada manuscrito foi realizada para os 44 trabalhos que atenderam todos os critérios de inclusão estabelecidos. As informações mais relevantes foram elencadas e brevemente discutidas a seguir.

a) Distribuição geográfica dos estudos e situação florestal dos principais países publicadores

Onze trabalhos não indicam o local de realização do estudo. Os 33 restantes distribuem-se em 4 continentes: América (16 trabalhos), Ásia (13), Europa (3) e África (2). É válido ressaltar que há um estudo compartilhado pela América e Europa, além do fato de que a Turquia é um país localizado em dois continentes (Europa e Ásia). Por sua vez, a ausência da Oceania é algo no mínimo intrigante já que a Austrália possui certo destaque no cenário florestal mundial. Os países que tiveram o maior número de trabalhos foram Brasil e Estados Unidos (8 cada um, compartilhando um trabalho entre eles e com a Colômbia e Itália), sendo os EUA o único representante da América do Norte, enquanto a América do Sul é representada por 3 países (Brasil, Colômbia e Peru). A China está em segundo lugar com 5 trabalhos, seguido por Malásia e Japão (3 trabalhos cada) e Congo (2), enquanto os demais países (7) possuem um trabalho cada.

O Brasil desempenha um papel crucial no mercado madeireiro mundial, com uma contribuição significativa para a produção e exportação de produtos florestais (Souza et al., 2020). Segundo dados da Organização das Nações Unidas para Alimentação e Agricultura (FAO), o Brasil é o quarto maior produtor de madeira serrada do mundo, com uma produção anual de aproximadamente 13,5 milhões de metros cúbicos em 2020 (FAO, 2021). Além disso, a indústria brasileira de celulose e papel é um dos maiores *players* mundiais, com uma produção de cerca de 20,6 milhões de toneladas em 2020 (IBÁ, 2021). Em relação ao mercado interno, de acordo com relatório do IBÁ (2023), o setor florestal brasileiro é responsável pela geração de mais de 2,6 milhões de empregos diretos e indiretos, além de corresponder a cerca de 1,3% do Produto Interno Bruto (PIB) do país.

Portanto, a correta identificação de madeiras é algo que possui grande impacto econômico tanto no mercado interno brasileiro como no mercado externo. Além disso, uma rápida identificação seria de grande valia em processos de fiscalização, já que o grande volume de madeira comercializado no país, em conjunto com os devidos processos burocráticos, é incomparável com o número insuficiente de profissionais (principalmente especializados), havendo um *gap* para o alcance de processos mais eficientes. É sabido que a identificação de madeiras apresenta grandes desafios, mas estudos indicam que

o uso de imagens, em conjunto com inteligência artificial, muitas vezes se equipara ou supera o percentual de acerto de anatomistas.

Os Estados Unidos é um dos países líderes no setor florestal, destacando-se tanto pela sua produção madeireira como pelo desenvolvimento tecnológico relativo a esse setor (McGinley et al., 2019). O investimento em pesquisa e desenvolvimento é impulsionado por agências como o Departamento de Agricultura dos Estados Unidos (USDA) e o Serviço Florestal dos Estados Unidos (USFS), que lideram iniciativas para promover a conservação, manejo sustentável e inovação no setor florestal. Esses esforços são justificados pela relevância da indústria florestal na economia do país, contribuindo significativamente para o PIB e gerando empregos em diversas regiões (Espinoza, 2020; McConnell et al., 2019).

Por sua vez, o valor total do setor madeireiro na China, em 2020, foi estimado em aproximadamente 133 bilhões de dólares americanos, abrangendo uma ampla gama de atividades relacionadas à produção, processamento e comercialização de produtos florestais, incluindo madeira serrada, papel, celulose, móveis e produtos derivados (Chen et al., 2020; Xiong et al., 2022;). A China possui grande variedade de espécies florestais, muitas das quais são endêmicas e possuem alto valor econômico (Zhang et al., 2020), apresentando uma produção total de madeira serrada de aproximadamente 124 milhões de metros cúbicos no ano de 2020 (FAO, 2021). A China tem investido significativamente em pesquisa e desenvolvimento no setor florestal, liderando iniciativas para promover a inovação e a adoção de tecnologias avançadas, refletindo o compromisso do país com a modernização e o progresso dentro da área florestal (Zhang et al., 2020).

Portanto, o destaque desses países na temática em questão possivelmente deriva da sua importância no setor florestal em concomitância com sua alta biodiversidade. A biodiversidade provavelmente é o ponto que justifica a ausência da produção científica sobre o tema em países destaque no desenvolvimento de tecnologia e dentro do top 10 de *players* mundiais do setor florestal, como Canadá, Suécia e Finlândia, países que possuem baixa diversidade de espécies (em comparação com Brasil, EUA e China) devido aos fatores geoclimáticos.

Em contrapartida, o continente africano possui 54 países e é representado apenas pelo Congo. A África é um continente rico em biodiversidade florestal, abrigando uma ampla variedade de espécies arbóreas em seus diversos ecossistemas, incluindo espécies endêmicas e ameaçadas de extinção (Cuni-Sanchez et al., 2021; Kikuta, 2020). Além de questões com a disponibilidade de financiamento e prioridades na alocação de recursos, diversas regiões do continente africano enfrentam conflitos internos que perduram há décadas e que afetam aspectos sociais, políticos e econômicos, algo que pode impactar negativamente o setor florestal local e que traz reflexos negativos também para suas relações comerciais e políticas. Portanto, a baixa representatividade deste continente pode ser uma consequência de todos os fatores supracitados que impactarão na priorização da alocação de recursos, potencialmente reduzindo o investimento em educação, ciência e novas tecnologias. Ao invés disto, esses recursos e esforços (quando disponíveis) estarão voltados para a melhoria de recursos básicos para a sobrevivência humana e qualidade de vida.

A riqueza biológica do continente africano é especialmente evidente em regiões como a bacia do Congo, considerada uma das áreas mais biodiversas do mundo e com a segunda maior cobertura florestal mundial (Nasi et al., 2011; De Wasseige et al., 2015). Contudo, o setor florestal congolês enfrenta desafios significativos, como a exploração madeireira ilegal, o desmatamento e a degradação do habitat (Brandt; Nolte; Agrawal, 2016; Lawson, 2014), problemas que devem ter impulsionado os estudos na temática de identificação de madeiras de maneira mais rápida, eficiente e menos dependente de mão-de-obra.

A partir desse cenário é possível inferir que o desenvolvimento de tecnologias de identificação de madeiras baseada em visão computacional é impulsionado e comandado por países que possuem alta biodiversidade, grande relevância na compra e/ou fornecimento de madeira e produtos derivados e com disponibilidade de recursos e investimento em educação, ciência e tecnologia. Contudo, indica-se que é de suma importância o envolvimento de outros países, especialmente daqueles historicamente *drivers* de desenvolvimento tecnológico para o avanço e difusão desse nicho tecnológico que impacta diretamente a conservação de florestas mundiais e um mercado que movimenta bilhões de dólares anualmente.

b) Espécies estudadas

A quantidade de espécies estudadas apresentou grande amplitude, variando de 4 (Santosa; Santosa, 2019) a 281 (Geus et al., 2020) espécies por trabalho, mas geralmente (cerca de 90% dos trabalhos) investigam menos de 30 espécies. No total, já foram estudadas 82 famílias, sendo majoritariamente folhosas, explicado pela sua maior diversidade. As famílias com maior número de representantes são Fabaceae (362), Lauraceae (112) e Sapotaceae (81), justificado por seu tamanho e diversidade, assim como grande relevância econômica. Da mesma maneira, os gêneros com o maior número de espécies estudadas foram aquelas com maior interesse econômico: *Quercus* (40), *Eucalyptus* (31) e *Pouteria* (31), em que os dois primeiros possuem milhares de hectares de floresta plantada mundialmente.

Discutindo-se especificamente a contribuição brasileira para a temática, as espécies mais pesquisadas são nativas da Mata Atlântica e Amazônia, biomas que já apresentam regulação legislativa para a extração de recursos madeireiros, inclusive restrição de corte e exploração. A Amazônia destaca-se como maior fornecedora nacional de madeira proveniente de florestas naturais e também como maior exportador desse segmento, reafirmando mais uma vez que essa temática é fruto de esforços regulatórios e com grande relevância econômica.

c) Preparo da superfície da amostra e plano anatômico utilizado para identificação

Cerca de 14 trabalhos não informaram se houve algum preparo da superfície. Dentre os demais, o instrumento mais utilizado é o micrótomo (12) seguido por lixa (11), mais comumente diversas gramaturas em sequência (Geus et al., 2020; He et al., 2020; Ravindran et al., 2022a; Ravindran et al., 2022b; Sun et al., 2021; Vieira et al., 2022), mas também apenas uma gramatura (Souza et al., 2020; Yang et al., 2022), seguida por objetos cortantes diversos (6). Um trabalho (Ravindran; Wiedenhoeft, 2022) foi classificado nas duas últimas categorias de forma concomitante, já que, entre outros parâmetros, compara o tipo de preparo da superfície da madeira para identificação. Um trabalho indicou o preparo de superfície como “*madeira serrada*” (Kwon et al., 2017), não indicando nenhum tipo de preparo adicional, e apenas um trabalho (Wu et al.,

2021) indicou que não houve preparo da superfície antes da aquisição das imagens.

O preparo de superfície das amostras está relacionado com o nível de identificação requerido, o tempo e recursos disponíveis. A identificação macroscópica é a mais utilizada em situações de fiscalização, devido ao menor tempo de preparo da amostra e de sua superfície e menor utilização de recursos, contudo muitas vezes não é possível chegar à identificação ao nível de espécie baseando-se somente na análise macroscópica. Nessas situações de fiscalização, geralmente é utilizado um objeto cortante (canivete ou faca) para retirar um pedaço (ou uma “camada”) da superfície da amostra e facilitar a visualização de caracteres anatômicos de interesse. Esse processo é, portanto, mais prático e menos oneroso, contudo, menos preciso e ainda exige conhecimentos específicos de anatomia da madeira e descrição anatômica de uma gama de espécies.

Por outro lado, a identificação microscópica necessita de mais tempo e recursos, exigindo uma superfície homogênea e maior precisão na visualização dos caracteres anatômicos, explorando detalhadamente as características anatômicas da amostra, sendo mais precisa e exigindo maior nível de especialização, conhecimento e acesso a coleções de referência e literatura. Nesse segundo cenário as amostras são preparadas utilizando diversas gramaturas de lixa e corte com lâmina em micrótomo de deslize. O preparo da superfície portanto é fator essencial para a visualização, discernimento e correta classificação do material.

A grande maioria dos trabalhos (31) realizou estudos/testes a partir de imagens apenas da face anatômica transversal; três estudos utilizaram as três faces; um relatou ambas as faces longitudinais; outro apenas indicou o termo “longitudinal”; e, por último, um apenas se referiu como “múltiplas seções” sem maiores especificações. Um total de 6 trabalhos não informaram qual face foi utilizada. Por mais que todas as faces da madeira apresentam informações relevantes para sua identificação anatômica, a face transversal é aquela em que a organização dos elementos anatômicos traz mais informações de maneira diagnóstica, sendo a mais utilizada e essencial para o método tradicional de identificação anatômica de madeiras, além de principal fonte de informações também para outros métodos de identificação.

Estudos com as três faces atingiram acurácia entre 95% e 98,7%; o estudo que não utilizou a face transversal apresentou acurácia de 90,5%. Por sua vez, no estudo que analisou apenas a face tangencial, a acurácia obtida foi de 83,7%; enquanto os estudos com apenas a face transversal apresentaram acurácia entre 65% e 100%. A escolha da face a ser avaliada deve levar em consideração o objetivo do estudo, o pré-processamento e os algoritmos de extração de características a serem empregados, assim como o método de classificação. Todos os itens previamente citados também sofrerão influência de outros fatores (como iluminação, angulação, etc. da imagem). Além disso, a acurácia é uma das métricas que indicam o sucesso da metodologia empregada e, mesmo sendo a principal, não deve ser considerada isoladamente.

d) Metodologias de aquisição e características das imagens

A maior parte (15) dos estudos usou microscópio (óptico ou eletrônico de varredura) em conjunto com câmeras, ou estereomicroscópio para a aquisição das imagens; seguido por câmeras digitais (8); sistema *Xylotron* (6); câmeras de celular (5, aqui incluídos também câmera de celular mais lente externa); e *scanners* (5). Dois trabalhos estudaram imagens espectrais obtidas a partir de equipamento do tipo NIR-HSI e 3 estudos não informaram qual o tipo de equipamento utilizado para a obtenção das imagens. A menor resolução obtida foi de 100x100 (estereomicroscópio), enquanto a maior foi de 4800x3600 (microscópio e lente digital) e a maior parte dos estudos apresentou resolução inicial igual ou abaixo de 3024 x 3024 pixels.

Quanto maior a resolução de uma imagem, maior é a quantidade de informações nela contida, sendo mais provável a extração de um maior número de características de interesse para a classificação. Contudo, como é necessário um grande volume de imagens para a obtenção de um modelo confiável, o processamento de imagens de alta resolução demora mais tempo e exige maior memória de armazenamento e processamento, sendo, portanto, onerosa e demorada. Por isso, diversos trabalhos indicaram o redimensionamento das imagens para menor resolução visando facilitar o subsequente processamento e reduzir custos computacionais, aumentando as chances de sua utilização em situações que o custo-benefício tem o tempo de processamento e obtenção de resultados como uma das principais prioridades.

O formato da imagem não parece ser algo relevante para a aquisição e posterior processamento de dados, já que apenas 5 trabalhos expuseram tal informação, utilizando-se dos seguintes formatos: PNG, TIFF e JPEG. Em razão do baixo número de trabalhos que explicitam essa especificação, acredita-se que há uma flexibilidade de formatos aceitos pelos mais diversos *softwares* de processamento. A magnificação (*zoom*) utilizada foi informada em pouco menos da metade dos trabalhos (21) e variou de 1 a 1500 vezes, mas geralmente até 20x. Assim como a resolução, a magnificação influencia na quantidade de informação disponível por imagem, já que quanto maior é a magnificação maior será o nível de detalhamento, contudo, menor será a superfície registrada e menor é a chance de representar em sua totalidade o conjunto do padrão anatômico específico de determinada espécie por imagem.

Um diverso e numeroso banco de dados é determinante para a construção de um bom modelo preditivo. Os trabalhos analisados tiveram como menor banco de dados o trabalho de Kanayama et al. (2019) que analisaram 120 imagens de 38 espécies no Japão utilizando câmera NIR-HSI, enquanto o mais numeroso foi compilado por Yang et al. (2022) compreendendo 29.680 imagens de 5 espécies na China utilizando microscópio e câmera CCD. Seis trabalhos não disponibilizaram tal informação.

Grande parte dos estudos tiveram banco de dados menores que 9 mil imagens e a maioria se encontra entre 2 mil e 3 mil imagens. A quantidade de imagens está diretamente relacionada com quão robusto e representativo é o modelo, algo que, no caso da madeira, vai além de questões puramente estatísticas, já que é um material que pode ter sua estrutura anatômica alterada em consequência da carga genética, idade, posição do tronco e condições edafoclimáticas, apresentando certa plasticidade. Portanto, é de suma importância a obtenção de um banco de dados que compreenda o máximo dessas variações representadas em um número significativo de imagens para garantir a precisão e acurácia do modelo, já que esses bancos são subdivididos (geralmente em três grupos: treino, validação e teste) nas etapas do processamento. Contudo, deve-se atentar ao equilíbrio entre acurácia e tempo de processamento, já que quanto maior o número de imagens, maior será seu tempo de processamento, elevando também os custos computacionais.

Para tentar contornar o problema de número de imagens *versus* custos de obtenção e disponibilidade de amostras, diversos trabalhos tem utilizado na etapa de pré-processamento a técnica de *data augmentation* que nada mais é que a aplicação de funções para aumentar o número e a variação de imagens. Nesta etapa as imagens podem ser cortadas (subdivididas), giradas em diversos ângulos, desfocadas (*blur*) e magnificadas a diferentes níveis, por exemplo, gerando um banco de dados mais numeroso e diverso. Ao aplicar essas funções também há um certo nível de simulação de imagens comumente obtidas em situações de campo: não bem anatomicamente orientadas e parcialmente desfocadas. Isto teoricamente influenciaria na sensibilidade da técnica e aproximaria o modelo de situações cotidianas, o que poderia resultar em uma maior viabilidade de aplicação para além de situações consideradas como ideais (ou de laboratório). Ainda na etapa de pré-processamento, é possível aplicar filtros e técnicas para melhorar a imagem, alterando por exemplo a iluminação e contraste, porém isso aumenta o uso dos recursos computacionais e o tempo de processamento.

e) Técnicas ou metodologias de análise

Os estudos aqui analisados majoritariamente utilizaram técnicas de redes neurais artificiais, especialmente redes convolucionais, tanto tradicionais como residual e rápida. Redes neurais artificiais (RNAs) são modelos computacionais inspirados no funcionamento do cérebro humano, projetados para aprender e realizar tarefas complexas. Segundo Haykin (2009), as RNAs são compostas por várias camadas de neurônios interconectados, cada um deles processando e transmitindo informações para as camadas subsequentes. Essas redes são capazes de aprender a partir de exemplos e generalizar padrões, tornando-as particularmente eficazes em tarefas de reconhecimento de padrões e classificação de dados (Lecun et al., 2015).

Os diferentes tipos de RNAs incluem as redes *feedforward*, como *perceptrons* multicamadas, e as redes recorrentes, que possuem conexões retroalimentadas e são adequadas para lidar com dados sequenciais, como séries temporais e linguagem natural (Graves et al., 2013). Entre os benefícios das RNAs, destacam-se sua capacidade de lidar com dados complexos e não lineares, sua adaptabilidade a diferentes domínios de aplicação e sua

capacidade de aprender padrões a partir de grandes conjuntos de dados (Goodfellow et al., 2016).

No entanto, as RNAs também apresentam algumas desvantagens. Em primeiro lugar, esses modelos são frequentemente considerados caixas-pretas, o que significa que o processo de tomada de decisão dentro da rede pode ser difícil de interpretar e explicar (Bengio et al., 2013). Além disso, as RNAs podem ser suscetíveis a *overfitting* (sobreajuste), especialmente quando aplicadas a conjuntos de dados pequenos ou ruidosos, o que pode levar a uma baixa capacidade de generalização (Bishop, 2006).

O *overfitting* significa que o modelo construído a partir dos dados observados não está generalizando bem quando confrontado com dados não previamente observados (Hawkins, 2004; Ying, 2019). Ou seja, o modelo performa perfeitamente no treinamento, mas fracamente durante a etapa de teste (Ying, 2019). Ainda de acordo com esse autor, modelos que atingem o *overfitting* tendem a **memorizar** (ao invés de **aprender**) os dados, apresentando dificuldade ao lidar com informações com o conjunto de dados de treinamento.

Outra desvantagem é a necessidade de grandes quantidades de dados de treinamento e alto poder computacional para treinar efetivamente as redes neurais, o que pode ser um obstáculo em situações com recursos limitados (Jordan; Mitchell, 2015). Portanto, embora as RNAs ofereçam vantagens significativas em termos de capacidade de aprendizado e desempenho em várias tarefas, é importante considerar suas limitações e desafios ao aplicá-las em contextos práticos, ajustando-as da melhor forma para adequá-las às limitações mantendo uma *trade-off* favorável entre custo benefício e performance.

Ao longo dos anos, o uso de *transfer learning* (transferência de aprendizado) tem se tornado mais frequente, destacando nos trabalhos analisados o uso de modelos pré-treinados, especialmente *ResNet* (*Residual Neural Network*), *Inception* e *DenseNet*. *Transfer learning* em redes neurais artificiais refere-se à técnica de treinar um modelo em uma tarefa e, em seguida, transferir o conhecimento aprendido para uma tarefa relacionada. Segundo Pan e Yang (2010), essa abordagem tem sido amplamente utilizada para melhorar o desempenho de modelos de aprendizado profundo, especialmente em situações em que há poucos dados disponíveis para treinamento. Existem diferentes tipos

de *transfer learning*, como *fine-tuning*, onde um modelo pré-treinado é ajustado para uma tarefa específica, e *feature extraction*, onde as características aprendidas por um modelo pré-treinado são usadas como entrada para um novo modelo (Yosinski et al., 2014). O principal benefício do uso de *transfer learning* é a capacidade de aproveitar o conhecimento prévio aprendido em grandes conjuntos de dados e aplicá-lo a novas tarefas com menos dados de treinamento, o que pode resultar em melhorias significativas no desempenho do modelo (Razavian et al., 2014) e na redução de custos computacionais e tempo de processamento.

No entanto, o *transfer learning* também apresenta algumas desvantagens. Uma delas é o risco de *overfitting*, especialmente quando o conjunto de dados de destino é pequeno ou muito diferente do conjunto de dados de origem (Yosinski et al., 2014). Além disso, a escolha inadequada do modelo pré-treinado ou da técnica de transferência pode levar a uma transferência ineficaz de conhecimento e a resultados subótimos (Yosinski et al., 2014). Outro desafio é a generalização das características aprendidas em um conjunto de dados específico para outros conjuntos de dados ou domínios, o que pode limitar a utilidade do *transfer learning* em certos contextos (Pan; Yang, 2010).

O *transfer learning* tem sido aplicado com sucesso na identificação de madeiras, oferecendo uma abordagem eficaz para lidar com conjuntos de dados limitados e heterogêneos. Estudos como o de Silva et al. (2022) demonstraram sua eficácia na classificação de imagens de texturas de madeira, utilizando modelos pré-treinados em conjuntos de dados gerais de imagens. Além disso, Zhang et al. (2020) exploraram o uso de *transfer learning* em combinação com técnicas de processamento de imagem, como redes neurais convolucionais, para identificar características específicas das texturas de madeira.

Existem várias redes de modelos pré-treinados que podem ser utilizadas para identificação de madeiras com o auxílio do *transfer learning*. A *ResNet* (*Residual Neural Network*) é uma arquitetura de rede neural profunda que se destacou em várias tarefas de visão computacional, incluindo classificação de imagens. Seus blocos residuais permitem o treinamento de redes mais profundas, facilitando a extração de características complexas das imagens de madeira. Outra rede amplamente empregada é a VGG (*Visual Geometry Group*), arquitetura conhecida por sua simplicidade e eficácia. Com várias camadas

convolucionais e de *pooling*, a VGG é capaz de capturar informações detalhadas das texturas de madeira, sendo uma escolha popular para tarefas de identificação e classificação de imagens. Por último, a rede *Inception*, desenvolvida pelo Google, é conhecida por sua capacidade de extrair características em diferentes escalas espaciais. Em razão dos módulos de convolução paralelos, esta rede é capaz de capturar detalhes finos e padrões complexos nas imagens de madeira, o que a torna uma opção promissora para aplicações de identificação.

Os principais algoritmos utilizados nos trabalhos analisados nesta revisão bibliométrica na etapa de extração de características de interesse foram o *Local binary patterns* (LBP) e o *Gray-Level Co-occurrence Matrix* (GLCM). LBP é uma técnica de descrição de textura que codifica a relação entre um pixel e seus vizinhos em uma imagem. Essa abordagem, proposta por Ojala et al. (2002), tem sido amplamente utilizada em tarefas de reconhecimento de padrões e visão computacional devido à sua simplicidade e eficácia. Suas aplicações incluem reconhecimento de rostos (Ahonen et al., 2006), detecção de objetos (Mikolajczyk; Schmid, 2005) e classificação de texturas (Zhao et al., 2010). Os benefícios do LBP incluem sua invariância a mudanças de iluminação e sua capacidade de capturar características locais importantes das imagens. No entanto, algumas desvantagens incluem sua sensibilidade a ruídos e sua limitação na representação de características globais da imagem (Heikkilä et al., 2009).

Já a GLCM é uma técnica de análise de textura que quantifica a relação espacial entre pares de pixels em uma imagem. Essa matriz, introduzida por Haralick et al. (1973), captura a frequência com que diferentes combinações de níveis de cinza ocorrem em uma determinada direção e distância. As aplicações do GLCM abrangem diversas áreas, incluindo reconhecimento de padrões, segmentação de imagem e classificação de texturas (Sarkar; Chaudhuri, 1994). Seus benefícios incluem a capacidade de capturar informações detalhadas sobre a textura da imagem e sua invariância a mudanças de iluminação e contraste. No entanto, algumas desvantagens do GLCM incluem sua sensibilidade a ruídos e sua dependência de parâmetros de configuração, como a escolha da distância e direção (Clausi, 2002).

Para a etapa de classificação, as técnicas mais utilizadas foram *Support Vector Machine* (SVM) e *k-Nearest Neighbor* (k-NN). As Máquinas de Vetores de Suporte (SVM) são um poderoso método de aprendizado supervisionado utilizado para tarefas de classificação e regressão. Proposta por Cortes e Vapnik (1995), a SVM busca encontrar o hiperplano de separação ótimo que maximiza a margem entre as classes, tornando-se robusta em espaços de alta dimensionalidade. Suas aplicações incluem classificação de imagens (Cortes; Vapnik, 1995), reconhecimento de padrões (Burges, 1998) e análise de séries temporais (Schölkopf et al., 2001). Os benefícios da SVM incluem sua eficácia em lidar com conjuntos de dados complexos e não lineares, com alta dimensionalidade e sua interpretabilidade do modelo final. No entanto, algumas desvantagens incluem a sensibilidade a parâmetros de ajuste, a dificuldade de lidar com conjuntos de dados muito grandes e sua ineficiência computacional em problemas de grande escala (Chang; Lin, 2011).

O k-NN é um método de aprendizado de máquina baseado em instâncias que classifica novos exemplos com base na maioria dos votos dos k exemplos mais próximos no espaço de características. Essa abordagem, introduzida por Cover e Hart (1967), é simples de implementar e intuitiva de entender, não requerendo uma fase de treinamento explícita. Suas aplicações incluem classificação de padrões (Altman, 1992), reconhecimento de padrões em imagens (Duda et al., 2000) e sistemas de recomendação (Ricci et al., 2015). Os benefícios do k-NN incluem sua facilidade de interpretação, sua capacidade de lidar com dados não lineares e sua robustez a dados ruidosos. No entanto, algumas desvantagens incluem sua sensibilidade a *outliers*, sua ineficiência computacional em conjuntos de dados grandes e sua necessidade de definir o valor de k de forma apropriada (Altman, 1992).

Por fim, a avaliação do modelo construído pode ser feita por diversas métricas. Nos estudos analisados, a métrica mais recorrente é a acurácia, seguida pelo *F1-score*, mas também podem ser calculadas a precisão, sensibilidade (*recall*) e especificidade. A acurácia é uma métrica fundamental em problemas de classificação em *machine learning*, definida como a proporção de predições corretas em relação ao total de predições feitas pelo modelo. Ela é calculada dividindo o número de predições corretas pelo número total de predições realizadas. A acurácia é amplamente utilizada devido à sua

simplicidade e interpretabilidade, fornecendo uma medida direta da eficácia geral do modelo. No entanto, sua utilidade pode ser limitada em casos de conjuntos de dados desbalanceados, onde uma classe é muito mais prevalente do que outras, o que pode levar a uma acurácia “inflada” e não representativa da verdadeira eficácia do modelo. Além disso, a acurácia pode não ser apropriada em situações em que os erros de diferentes tipos têm custos diferentes, como em problemas de detecção de fraudes ou diagnósticos médicos (Fawcett, 2006; Galar et al., 2012; Powers, 2011; Saito; Rehmsmeier, 2015; Sokolova; Lapalme, 2009).

O F1-score é calculado como a média harmônica da precisão e do *recall*, oferecendo uma maneira de avaliar a capacidade de um modelo em fazer previsões precisas e abrangentes ao mesmo tempo. O F1-score é especialmente útil em situações de conjuntos de dados desbalanceados, onde uma classe é muito mais prevalente do que outras, pois ele leva em consideração tanto os falsos positivos quanto os falsos negativos. No entanto, assim como a acurácia, o F1-score pode não ser adequado em cenários onde os erros de diferentes tipos têm custos diferentes, exigindo uma ponderação diferenciada entre precisão e *recall* (Davis; Goadrich, 2006; Galar et al., 2012; Powers, 2011; Saito; Rehmsmeier, 2015; Sokolova; Lapalme, 2009).

f) Outras considerações

A tendência para os próximos anos indica o uso de tecnologias mais acessíveis, tanto financeiramente quanto a interface e facilidade de uso, destacando o uso de *smartphones* (especialmente com lentes acopladas das mais simples a mais robustas e especializadas) e microscópios digitais portáteis (também dos baratos e simples a mais caros, robustos e especializados). Já existem equipamentos/sistemas desenvolvidos com o objetivo específico de auxiliar na identificação de madeiras, destacando-se o equipamento e *software XyloTron*, desenvolvido em parceria com a USDA, laboratórios de pesquisa e universidades americanas. Outra tendência, desta vez focada na criação de modelos e processamento de dados, é a diversificação de tipos de RNAs e o uso de *transfer learning* visando uma maior acurácia e redução de tempo de processamento e recursos operacionais, destacando-se neste último também o processamento em nuvem.

Diversos grupos já estabeleceram bancos de dados para grupos de espécies economicamente relevantes, principalmente em contextos locais, contudo, o número de bancos de dados disponíveis de maneira pública ainda é limitado, destacando-se no contexto brasileiro a contribuição da Universidade Federal do Paraná com três bancos de dados distintos abrangendo espécies florestais de interesse econômico nacional e espécies vulneráveis ou com risco de extinção.

Além das dificuldades impostas nos processos de obtenção de amostras e aquisição de imagens, existe uma barreira quanto à criação, utilização e refinamento das técnicas e plataformas de criação de modelos e processamento, já que muitas delas exigem conhecimentos sobre programação e estatística em níveis médios a avançados, não sendo acessíveis para leigos. O *software* R é um dos mais acessíveis quanto a isso, mas ainda exige um certo nível de conhecimento sobre programação. Por outro lado, quando se tem esses conhecimentos, geralmente o profissional não é familiarizado com a anatomia da madeira, seus fundamentos, características e variações, muitas vezes não apresentando repertório suficiente para a compreensão em sua totalidade e, conseqüentemente, para a discussão desses resultados em termos botânicos. A intersecção desses conhecimentos em um único profissional altamente especializado é limitada, já que são poucos os que se aventuram em duas áreas do conhecimento tão distintas. Portanto, o elemento chave para solucionar esses *gaps* sem sobrecarregar determinado tipo de profissional, é a cooperação interdisciplinar entre pesquisadores e grupos das duas áreas para um fim comum.

A quantidade de espécies já estudadas ainda é relativamente pequena quando comparado às espécies madeireiras já descritas em um contexto mundial. Ademais, ainda não existe um site/plataforma/*software* que suporte um banco de dados colossal necessário para a universalidade deste tipo de identificação, sendo existentes, em sua maioria, esforços locais (geralmente espécies de importância econômica dentro de um mesmo país), destacando-se a parceria entre EUA e Brasil como o esforço de maior sucesso (também em número de espécies) que ultrapassa limites nacionais.

Ainda sobre universalidade, existem alguns obstáculos para que ela seja alcançada de maneira satisfatória, como a falta de padronização das imagens e

disponibilização de dados de maneira pública por especialistas credenciados. Em relação às dificuldades, é válido ressaltar que a homogeneização de amostras quanto à sua superfície, luminosidade, ângulo de obtenção, orientação anatômica e superfície amostrada é inviável em situações de campo, em que a variação é significativa entre operadores, localidades e equipamentos empregados.

Ao refletir sobre essas problemáticas, pesquisou-se sobre sistemas, metodologias e técnicas já existentes para minimizar tais questões ao mesmo tempo que atingem uma boa acurácia, reprodutibilidade e possuem sensibilidade suficiente para conseguir extrair características de interesse e processar a classificação, mesmo em cenários com diversas fontes e níveis de variação para imagens de maneira geral, e que poderiam potencialmente facilitar a identificação de madeiras. Dentre elas, destacou-se o YOLO (*You Only Look Once*), um dos mais proeminentes algoritmos de detecção em tempo real utilizado em visão computacional da atualidade.

Proposto por Redmon et al. em 2016, o YOLO inovou ao introduzir um método único que permite realizar a detecção de objetos em apenas uma passagem pela rede neural (por isso recebendo a denominação de *You Only Look Once*, traduzido livremente como “você olha uma única vez”), tornando-o extremamente eficiente em termos de velocidade de processamento (Redmon et al., 2016). Diferente de abordagens anteriores, que dividiam a detecção em várias regiões de interesse, o YOLO opera utilizando uma única rede neural, que prediz simultaneamente as coordenadas dos *bounding boxes* e as probabilidades das classes dos objetos presentes na imagem de entrada. Essa arquitetura resulta em detecções mais rápidas e precisas, tornando-o altamente atrativo para aplicações em tempo real, como carros autônomos e sistemas de segurança (Bochkovskiy et al., 2020).

Uma das principais características do YOLO é sua capacidade de oferecer detecção de objetos em tempo real, alcançando taxas de quadros por segundo (fps, *frames per second*, também comumente denominada como *frames* por segundo) muito altas, mesmo em *hardware* de baixo custo (Redmon; Farhadi, 2018). Além disso, o YOLO é capaz de lidar com uma ampla variedade de classes de objetos em diferentes cenários, tornando-o altamente versátil para aplicações práticas (Redmon; Farhadi, 2018). Sua eficiência e precisão o tornam

uma escolha popular para sistemas embarcados e aplicações em dispositivos móveis (Bochkovskiy et al., 2020). No entanto, uma desvantagem do YOLO é que ele pode enfrentar dificuldades em detectar objetos muito pequenos ou ocultos, devido à sua abordagem de detecção baseada em *grid*. Além disso, em cenários de alta densidade de objetos, o YOLO pode ocasionalmente confundir objetos sobrepostos ou próximos (Redmon; Farhadi, 2018).

Embora o YOLO seja mais comumente associado às aplicações de visão computacional em detecção de objetos urbanos e industriais, sua aplicação na engenharia florestal tem sido cada vez mais explorada. Em particular, tem sido empregado na detecção individual de árvores em pé e densidade arbórea de florestas, contribuindo para estudos sobre biodiversidade florestal e facilitação de inventários florestais (Wang et al., 2023). Outros estudos, como os de Zhao et al. (2019) e Zhu et al. (2020), exploraram o uso do YOLO para detectar e mapear áreas de desmatamento e degradação florestal, fornecendo informações importantes para conservação e monitoramento ambiental.

Na indústria madeireira, o YOLO já tem sido aplicado para a identificação e classificação de defeitos (Cui; Lu; Liu, 2023; Fang et al., 2021; Kurdthongmee; Suwannarat, 2019; Meng; Yuan, 2023; Wang et al., 2023) e na contagem de elementos (unidades de toras e tábuas) em pilhas de madeira no pátio (Casas et al., 2023; Praschl et al., 2021) no contexto de indústria 4.0. Na identificação de espécies de madeira, há o estudo de Rosli et al. (2021) sobre madeiras tropicais, com acurácia maior que 95%, utilizando o YOLOv3 e, na anatomia, a aplicação de YOLOv5 para medição de raios em coníferas com acurácia superior a 93% (Guo et al., 2023). Portanto, para o próximo capítulo propõe-se testar a eficiência da versão mais recente, YOLOv8, para a identificação/distinção de madeiras.

1.5 CONSIDERAÇÕES DO CAPÍTULO

A análise desta revisão indica que o tema tem gerado publicações de artigos científicos em pouco mais de uma década, sendo considerado como um tema recente que demonstra tendência de expansão nos próximos anos. O Brasil e os Estados Unidos estão na vanguarda no desenvolvimento e aplicação de técnicas para a identificação de madeiras combinando imagens e técnicas de aprendizado de máquina, já inclusive aplicando essa tecnologia em recursos móveis. Também foi identificado o maior uso de técnicas de aprendizado profundo (*deep learning*) e de transferência de aprendizado (*transfer learning*), em conjunto com a portabilidade de recursos, o uso de tecnologias mais acessíveis, tanto financeiramente quanto a interface e facilidade de uso, são as tendências indicadas para trabalhos nos próximos anos.

Os principais desafios continuam os mesmos há cerca de uma década e se referem à aquisição do banco de dados, qualidade das informações das imagens e a homogeneização das amostras e controle das variáveis durante o processo de aquisição. Além disso, aparenta ser necessário uma maior aproximação entre as práticas estudadas em situação de laboratório e as condições enfrentadas em situações de campo. Os custos operacionais, recursos computacionais e o tempo desde o preparo da amostra até o processamento do modelo e a intersecção entre conhecimentos computacionais e da anatomia da madeira ainda são questões relevantes que necessitam de mais estudos e testes.

REFERÊNCIAS

- AHONEN, T.; HADID, A.; PIETIKAINEN, M. Face description with local binary patterns: Application to face recognition. **IEEE Transaction Pattern Analysis and Machine Intelligence**, v. 28, n. 12, p. 2037–2041, 2006.
- ALTMAN, N. S. An Introduction to kernel and nearest neighbor nonparametric regression. **The American Statistician**, n. 46, p. 175-185, 1992.
- ARIA, M.; CUCCURULLO, C. Bibliometrix: An R-tool for comprehensive science mapping analysis. **Journal of Informetrics**, v.11, n.4, pp 959-975, 2017.
- BENGIO, Y.; COURVILLE, A.; VINCENT, P. Representation learning: a review and new perspectives. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, n. 35, p. 1798–1828, 2013.
- BISHOP C.M. **Pattern Recognition and Machine Learning**. New York: Springer-Verlag, 2006. 758p.
- BOCHKOVSKIY, A.; WANG, C-Y.; LIAO, H-Y. YOLOv4: Optimal Speed and Accuracy of Object Detection. arXiv preprint arXiv:2004.10934, 2020.
- BRANDT, J. S.; NOLTE, C; AGRAWAL, A. Deforestation and timber production in Congo after implementation of sustainable forest management policy. **Land Use Policy**, v 52, p.15-22, 2016.
- BURGESS, C. J. C. A tutorial on support vector machines for pattern recognition. **Data Mining and Knowledge Discovery**, v. 2, p. 121-167, 1998.
- CASAS, G. G.; ISMAIL, Z. H.; LIMEIRA, M. M. C.; SILVA, A. A. L. da; LEITE, H. G. Automatic detection and counting of stacked eucalypt timber using the Yolov8 model. **Forest**, v. 14, n. 12, p. 2369, 2023.
- CHANG, C. C.; LIN, C. J. LIBSVM: A library for support vector machines. **ACM Transactions on Intelligent Systems and Technology**, v. 2, p. 27, 2011.
- CHEN, J.; WANG, L.; LI, L.; MAGALHÃES, J.; SONG, W.; LU, W.; XIONG, L.; CHANG, W-Y.; SUN, Y. Effect of forest certification on international trade in forest products. **Forests**, v. 11, n. 12, 1270, 2020.
- CLAUSI, D.A. An analysis of co-occurrence texture statistics as a function of gray level quantization. **Canadian Journal of Remote Sensing**, v. 28, n. 1, p. 45-62, 2002.
- CORTES, C.; VAPNIK, V. Support-vector networks. **Machine Learning**, n. 20, p. 273–297, 1995.
- COVER, T.; HART, P. Nearest neighbor pattern classification. **IEEE Transactions on Information Theory**, n. 13, p. 21-27, 1967.

CUI, Y.; LU, S.; LIU, S. Real-time detection of wood defects based on SPP-improved YOLO algorithm. **Multimedia Tools and Applications**, v. 82, n. 14, p. 21031-21044, 2023.

CUNI-SANCHEZ, A. et al. High aboveground carbon stock of African tropical montane forests. **Nature**, v. 596, n.7873, p. 536-542, 2021.

DAVIS, J.; GOADRICH, M. The relationship between precision-recall and ROC curves. **Proceedings of the 23rd International Conference on Machine Learning**, 2006.

DE WASSEIGE, C.; TADOUM, M.; EBAA-ATYI, R.; DOUMENGE, C. **The forests of the Congo Basin-Forests and climate change**. Technical report, 2015.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**. Wiley-Interscience, 2000. 738p.

ESPINOZA, O. Trends in the US forest products sector, markets, and technologies. In: Dockry, M. J.; Bengston, D. N.; Westphal, L. M., comps. **Drivers of change in US forests and forestry over the next 20 years**. P. 26-49, 2020.

FALAGAS, M. E.; PITSOUNI, E. I.; MALIETZIZ, G. A.; PAPPAS, G. Comparison of PubMed, Scopus, web of science, and Google scholar: strengths and weaknesses. **The FASEB Journal**, v. 22, n. 2, p. 338-342, 2008.

FANG, Y.; GUO, X.; CHEN, K.; ZHOU, Z.; YE, Q. Accurate and automated detection of surface knots on sawn timbers using YOLO-V5 mode. **BioResources**, v. 16, n. 3, p. 5390-5406, 2021.

FAO. **The state of the world's forests**. 2021.

FAWCETT, T. An introduction to ROC analysis. **Pattern Recognition Letters**, v. 27, n. 8, p.862-874, 2006.

GALAR, D.; GUSTAFSON, A.; TORMOS, B.; BERGES, L. Maintenance decision making based on different types of data fusion. **Eksploatacja i Niezawodność – Maintenance and Reliability**, v. 14, n. 2, p. 135–144, 2012.

GASPARYAN, A. Y.; AYVAZYAN, L.; BLAKMORE, H.; KITAS, G. D. Writing a narrative biomedical review: considerations for authors, peer reviewers, and editors. **Rheumatology international**, v. 31, p. 1409-1417, 2011.

GEUS, A. R., SILVA, S. F., GONTIJO, A. B., SILVA, F. O., BATISTA, M. A., SOUZA, J. R. An analysis of timber sections and deep learning for wood species classification. **Multimedia Tools and Applications**, v.79, n.45, p.34513-34529, 2020.

GRAVES, A.; MOHAMED, A.-R.; HINTON, G. E. Speech recognition with deep recurrent neural networks. **IEE International Conference on Acoustics, Speech and Signal Processing**, p. 6645-6649, 2013.

GOODFELLOW, I.; COURVILLE, A.; BENGIO, Y. **Deep Learning**. MIT Press, Cambridge, 2016. 775p.

GUO, Y.; WANG, W.; LIN, Q.; WANG, H.; WENG, J.; CHEN, W. Automatic recognition and calculation of softwood ray height based on tangential section images by using YOLOv5. In: **2023 China Automation Congress (CAC)**. IEEE, 2023. p. 7116-7121.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. **IEEE Transactions on Systems, Man, and Cybernetics**, v. SMC-3, n. 6, p. 610-621, 1973.

HAWKINS, D. M. The Problem of Overfitting. **Journal of chemical information and computer sciences**, v. 44, n. 1, p. 1-12, 2004.

HAYKIN, S. **Neural networks and learning machines**. Prentice Hall/Pearson, New York, 2009.938p.

HE, T.; LU, Y.; JIAO, L.; ZHANG, Y.; JIANG, X.; YIN, Y. Developing deep learning models to automate rosewood tree species identification for CITES designation and implementation. **Holzforschung**, v. 74, n.12, p.1123-1133, 2020.

HEIKKILÄ, M.; PIETKÄINEN, M.; SCHMID, C. Description of interest regions with local binary patterns. **Pattern Recognition**, v. 42, n. 3, p. 425-436, 2009.

HWANG, S.; 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, 2021.

IBÁ. **Relatório técnico anual**: ano de referência 2020. 2021.

IBÁ. **Relatório técnico anual**: ano de referência 2022. 2023.

JORDAN, M. I.; MITCHELL, T. M. Machine learning: trends, perspectives, and prospects. **Science**, v. 349, n. 6245, p.255-260, 2015.

KANAYAMA, H.; MA, T.; TSUCHIKAWA, S.; INAGAKI, T. Cognitive spectroscopy for wood species identification: near infrared hyperspectral imaging combined with convolutional neural networks. **Analyst**, v.144, n.21, p. 6438-6446, 2019.

KHUDZARI, J.; KURIAN, J.; TARTAKOVKY, B.; RAGHAVAN, G. S. V. Bibliometric analysis of global research trends on microbial fuel cells using Scopus database. **Biochemical Engineering Journal**, v. 136, p. 51-60, 2018.

KIKUTA, K. The environmental costs of civil war: a synthetic comparison of the Congolese forests with and without the Great War of Africa. **The Journal of Politics**, v.82, n.4, p.1243-1255, 2020.

KULKARNI, A. V.; AZIZ, B.; SHAMS, I.; BUSSE, J. W. Comparisons of citations in Web of Science, Scopus, and Google Scholar for articles published in general medical journals. **Jama**, v. 302, n. 10, p. 1092-1096, 2009.

KURDTHONGMEE, W.; SUWANNARAT, K. Locating wood pith in a wood stem cross sectional image using YOLO object detection. **International Conference on Technologies and Applications of Artificial Intelligence**, 2019.

KWON, O.; LEE, H. G.; LEE, M. R.; JANG, S.; YANG, S.Y.; PARK, S.Y.; CHOI, I. G.; YEO, H. Automatic wood species identification of Korean softwood based on convolutional neural networks. **Journal of the Korean Wood Science and Technology**, v.45, n.6, p.797-808, 2017.

LAWSON, S. Illegal logging in the Democratic Republic of the Congo. **Energy, Environment and Resources EER** (2014): 2014.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep Learning. **Nature**, n. 521, p. 436-444, 2015.

MARTÍN-MARTÍN, A.; ORDUNA-MALEA, E.; THELWALL, M.; LÓPEZ-CÓZAR, E. D. Google Scholar, Web of Science, and Scopus: A systematic comparison of citations in 252 subject categories. **Journal of Informetrics**, v. 12, n. 4, p. 1160-1177, 2018.

MCCONNELL, T. E.; TANGER, S. M.; JAMES, E. H. International trade's contributions to the United States forest sector and its import–export chain. **Journal of Forestry**, v. 117, n. 3, 210-225, 2019.

MCGINLEY, K. A.; GULDIN, R. W.; CUBBAGE, F. W. Forest sector research and development capacity. **Journal of Forestry**, v. 117, n. 5, p. 443-461, 2019.

MENG, W.; YUAN, Y. SGN-YOLO: detecting wood defects with improved YOLOv5 based on semi-global network. **Sensors**, v. 23, n. 21, 8705, 2023.

MIKOLAJCZYK, K.; SCHMID, C. A performance evaluation of local descriptors. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 27, n. 10, p. 1615-1630, 2005.

MOED, H. F. New developments in the use of citation analysis in research evaluation. **Archivum immunologiae et therapeuticae experimentalis**, v. 57, p. 13-18, 2009.

MONTOYA, F. G.; ALCAYDE, A.; BAÑOS, R.; MANZANO-AGUGLIARO, F. A fast method for identifying worldwide scientific collaborations using the Scopus database. **Telematics and Informatics**, v. 35, p. 168-185, 2018.

NASI, R.; PUTZ, F. E.; PACHECO, P.; WUNDER, S.; ANTA, S. Sustainable forest management and carbon in tropical Latin America: the case for REDD+. **Forests**, v. 2, p. 200–217, 2011.

OJALA, T.; PIETIKAINEN, M.; MAENPAA, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 24, n. 7, p. 971-987, 2002.

PAN, S. J.; YANG, Q. A survey on transfer learning. **IEEE Transactions on Knowledge and Data Engineering**, v. 22, n. 10, p.1345–59, 2010.

PATRO, P.; MISRA, D. P. Registering and reporting systematic reviews. **Central Asian Journal of Medical Hypotheses and Ethics**, v.1, n.2, p.122-126, 2020.

POWERS, D. M. W. Evaluation: from precision, recall and f-measure to ROC, informedness, markedness & correlation. **International Journal of Machine Learning Technology**, v. 2, n. 1, p.37-63, 2011.

PRASCHL, C.; PONTNER, A.; BOUMGARTNER, D.; ZWETTLER, G. A. Imaging framework: an interoperable and extendable connector for image-related Java frameworks. **SoftwareX**, v. 16, 100863, 2021.

R Core Team (2023). R: A Language and environment for statistical computing. R foundation for statistical computing, Vienna, Austria. <<https://www.R-project.org/>>.

RAVINDRAN, P.; OWENS, F. C.; WADE, A. C.; SHMULSKY, R.; WIEDENHOEFT, A. C. Towards sustainable North American wood product value chains, part I: Computer vision identification of diffuse porous hardwoods. **Frontiers in Plant Science**, v. 12, p. 758455, 2022a.

RAVINDRAN, P.; WADE, A. C.; OWENS, F. C.; SHMULSKY, R.; WIEDENHOEFT, A. C. Towards sustainable North American wood product value chains, part 2: Computer vision identification of ring-porous hardwoods." **Canadian Journal of Forest Research**, v.52, n.7, p. 1014-1027, 2022b.

RAVINDRAN, P.; WIEDENHOEFT, A. C. Caveat emptor: on the need for baseline quality standards in computer vision wood identification. **Forests**, v. 13, n.4, p. 632, 2022.

RAZAVIAN, A. S.; AZIZPOUR, H.; SULLIVAN, J.; CARLISSON, S. CNN features off-the-shelf: an astounding baseline for recognition. **IEEE Conference on Computer Vision and Pattern Recognition**, 2014.

REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHARDI, A. You only look once: unified, real-time object detection. **IEEE Conference on Computer Vision and Pattern Recognition**, 2016.

REDMON, J.; FARHADI, A. YOLOv3: An Incremental Improvement. **Computer Science**, arXiv: 1804.02767, 2018.

RICCI, F.; ROKACH, L.; SHAPIRA, B. **Recommender systems: introduction and challenges**, pp.1-34. Springer Link, 2015.

ROSLI, N. R.; KHAIRUDDIN, U.; FATHI, M. F. N.; KHAIRUDDIN, A. S. M.; AHMAD, A. Real-Time KenalKayu System with YOLOv3. In: **Advances in Robotics, Automation and Data Analytics: Selected Papers from iCITES 2020**. Springer International Publishing, 2021. p. 224-232.

SARKAR, N.; CHAUDHURI, B. B. An efficient differential box counting to compute fractal dimension of image. **IEEE Transactions on Systems Man and Cybernetics**, n. 24, p.115-120, 1994.

SAITO, T.; REHMSMEIER, M. The Precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. **PLoS ONE**, v. 10, n. 3, e0118432, 2015.

SANTOSA, S.; SANTOSA, Y. Wood types classification using back-propagation neural network based on genetic algorithm with gray level co-occurrence matrix for features extraction. **IAENG International Journal of Computer Science**, v.46, n.2, p. 149-155, 2019.

SCHÖLKOPF, B.; PLATT, J. C.; SHAWE-TAYLOR, J.; SMOLA, A. J.; WILIAMSON, R. C. Estimating the support of a high dimensional distribution. **Neural Computation**, v. 13, n.7, p. 1443-1471, 2001.

SILVA, J. L.; BORDALO, R.; PISSARA, J.; PALACIOS, P. Computer vision-based wood identification: A review. **Forests**, v. 13, n. 12, p. 2041, 2022.

SILVA, T. C.; ARAUJO, E. C. G.; LINS, T. R. S.; REIS, C. A.; SANQUETA, C. R.; ROCHA, M. P. Non-timber forest products in Brazil: a bibliometric and a state-of-the-art review. **Sustainability**, v. 12, n. 17, p. 7151, 2020.

SOKOLOVA, M.; LAPALME, G. A systematic analysis of performance measures for classification tasks. **Information Processing & Management**, v. 45, n. 4, p. 427-437, 2009.

SOUZA, D.V.; SANTOS, J. X.; VIEIRA, H. C.; NAIDE, T. L.; NISGOSKI, S.; OLIVEIRA, L. E. S. An automatic recognition system of Brazilian flora species based on textural features of macroscopic images of wood. **Wood Science and Technology**, v. 54, p.1065–1090, 2020.

SUGIARTO, B.; GOJALI, E. A.; HERLAN, H.; LESTARI, P. A smartphone-based of wood identification using image feature extraction. **Journal of Computer Science and Informatics Engineering**, v. 4, n. 1, p. 9-15, 2020.

SUN, Y.; LIN, Q.; HE, X.; ZHAO, Y.; DAI, F.; QIU, J.; CAO, Y. Wood species recognition with small data: A deep learning approach. **International Journal of Computational Intelligence Systems**, v.14, n.1, p.1451-1460, 2021.

TURHAN, K.; SERDAR, B. Support vector machines in wood identification: the case of three Salix species from Turkey. **Turkish Journal of Agriculture and Forestry**, v. 37, n. 2, p. 249-256, 2013.

VIEIRA, G. L. S.; PONTE, M. J. M. da; MOUTINHO, V. H. P.; JARDIM-GONÇALVES, R.; LIMA, C. P.; VINAGRE, M. V. A. Identification of wood from the Amazon by characteristics of Haralick and Neural Network: image segmentation and polishing of the surface. **iForest-Biogeosciences and Forestry**, v.15, n.4, p. 234-239, 2022.

WANG, Z.; LI, P.; CUI, Y.; LEI, S.; JANG, Z. Automatic detection of individual trees in forests based on airborne LiDAR data with a tree region-based convolutional neural network (RCNN). **Remote Sensing**, v. 15, n. 4, p. 1024, 2023.

WU, F.; GAZO, R.; HAVIAROVA, E.; BENES, B. Wood identification based on longitudinal section images by using deep learning. **Wood Science and Technology**, v.55, p.553-563, 2021.

XIONG, L.; ZHAO, H.; WANG, F.; CHENG, B. Genuine performance of China's forest products trade: An evaluation from the perspective of global value chains. **Forest Policy and Economics**, v. 144, 102823, 2022.

YANG, N.; BAI, Y.; JIANG, S.; YANG, C.; XU, K. Recognition method of plate and wood based on AlexNet optimization. **Scientia Silvae Sinicae**, v. 58, n. 3, p.149-158, 2022.

YING, X. An overview of overfitting and its solutions. **Journal of physics: Conference series**, 1168, p. 022022, 2019.

YOSINSKI, J.; CLUNE, J.; BENGIO, Y.; LIPSON, H. How transferable are features in deep neural networks? **Conference: advances in neural information processing systems**, 2014.

ZHANG, X.; KE, S.; XU, T.; QIAO, D. Review of China's Forestry Industry over the Past 70 Years and an Outlook for the Future. **International Forestry Review**, v. 22, n. 2, p. 269-282, 2020.

ZHAO, G.; HUANG, X.; GIZATDINOVA, Y.; PIETIKÄINEN, M. Combining dynamic texture and structural features for speaker identification, in: **Proceedings of ACM Multimedia Workshop Multimedia in Forensics, Security and Intelligence**, p. 93-98., 2010.

ZHAO, Z. Q.; ZHENG, P.; XU, S.T.; WU, X. Object detection with deep learning: a review. **IEEE Transactions on Neural Network Learning Systems**, v. 30, n. 11, p. 3212-3232, 2019.

ZHU, X.; SU, W.; LU, L.; LI, B.; WANG, X.; DAI, J.. Deformable DETR: Deformable transformers for end-to-end object detection. arXiv preprint arXiv:2010.04159, 2020.

CAPÍTULO 2

YOLOV8 PARA A IDENTIFICAÇÃO DE MADEIRAS TROPICAIS POR MEIO DE IMAGENS MACROSCÓPICAS

RESUMO

A tecnologia YOLO é comumente utilizada para a detecção de objetos e já empregado na indústria madeireira para classificação de qualidade da madeira em indústrias. Em razão disso, foi testada a eficiência de YOLOv8 para a identificação/distinção de espécies madeiras a partir de 5 bancos de dados de imagens macroscópicas das superfícies transversais obtidas com diferentes equipamentos (celular, câmera digital, estereomicroscópio, microscópio USB), diferentes ampliações e preparo de superfície distintos (lixas de diferentes grãos, lâmina de micrótomo de deslize, corte não homogêneo com objeto cortante). Todos os testes realizados com YOLOv8 apresentaram acurácia geral acima de 99% e métricas de desempenho que indicam positivamente a precisão, sensibilidade e capacidade preditiva dos modelos e algoritmo aplicado. Com um volume total de mais de 11 mil imagens, pode-se constatar o grande potencial de YOLOv8 para a identificação/distinção de madeiras por meio do modo de classificação do algoritmo. Esses resultados se destacam especialmente em razão das imagens terem sido obtidas com diferentes equipamentos, diferente ampliação e preparo de superfície distintos, indicando seu potencial para aplicação em sistemas mais complexos, robustos e universais de identificação/distinção já que sua acurácia não foi afetada (ou pouco afetada) pelas fontes mais comuns de variação. Ou seja, estes resultados podem indicar o YOLOv8 como uma alternativa viável para um sistema de identificação mundial aberto e alimentado por diversos especialistas, laboratórios e outras instituições credenciadas, que facilitaria a identificação de madeiras por leigos ou órgãos fiscalizadores de maneira mais rápida e menos onerosa.

Palavras-chave: YOLO; redes neurais convolucionais; reconhecimento/distinção de espécies madeiras; identificação baseada em imagem

YOLOV8 FOR TROPICAL WOOD IDENTIFICATION USING MACROSCOPIC IMAGES

ABSTRACT

YOLO technology is commonly used for object detection and has already been used in the wood industry to classify wood quality. For this reason, the efficiency of YOLOv8 for identifying/distinguishing wood species was tested using 5 databases of macroscopic cross-sectional images obtained with different equipment (cell phone, digital camera, stereomicroscope, USB microscope), different magnifications and different surface preparations (sandpaper with different grits, sliding microtome blade, inhomogeneous cut with a sharp object). All the tests performed with YOLOv8 showed overall accuracy above 99% and performance metrics that positively indicate the accuracy, sensitivity and predictive capacity of the models and algorithm applied. With a total volume of more than 11,000 images, the great potential of YOLOv8 for identifying/distinguishing wood through the algorithm's classification mode can be seen. These results stand out in particular because the images were taken with different equipment, different magnification and different surface preparation, indicating its potential for application in more complex, robust and universal identification/distinction systems, since its accuracy was not affected (or little affected) by the most common sources of variation. In other words, these results may indicate YOLOv8 as a viable alternative for an open global identification system fed by various experts, laboratories and other accredited institutions, which would facilitate the identification of wood by laypeople or inspection bodies in a faster and less costly way.

Keywords: YOLO; convolutional neural networks; wood species recognition/distinction; image-based identification

2.1 INTRODUÇÃO

A identificação de madeiras é uma área de pesquisa que tem atraído crescente interesse devido à sua importância em várias indústrias, como a de móveis, construção e preservação ambiental. Nos últimos anos, avanços significativos foram feitos na aplicação de técnicas de aprendizado de máquina para a identificação precisa e automatizada de espécies de madeira com base em imagens.

O uso de recursos computacionais para auxiliar a identificação de madeiras remonta a década de 80 (Kuroda, 1987; Lapasha; Wheeler, 1987; Pearson; Wheeler, 1981) e os avanços mais recentes tem aliado visão computacional e aprendizado de máquina, com destaque para a aplicação de redes neurais artificiais convolucionais (Hwang; Sugiyama, 2021). Técnicas de processamento de imagens têm sido amplamente exploradas para extrair informações úteis das texturas da madeira, como padrões de grã e poros, que são então utilizadas como características de entradas para algoritmos de aprendizado de máquina. Essas abordagens têm se mostrado eficazes na diferenciação entre diferentes tipos de madeira, mesmo quando as diferenças visuais são sutis.

No entanto, é importante notar que a identificação de madeira por meio de imagens e técnicas de aprendizado de máquina ainda enfrenta desafios, especialmente em relação à disponibilidade de conjuntos de dados representativos e à generalização para diferentes condições de iluminação, preparo de superfície e equipamentos de aquisição de imagens. Além disso, a interpretação correta das características visuais da madeira requer considerável nível de especialização, o que pode afetar a qualidade e a robustez dos modelos desenvolvidos.

2.2 OBJETIVOS

2.2.1 Objetivo geral

O objetivo geral deste capítulo é testar a eficiência de YOLOv8 na identificação/distinção de madeiras a partir de imagens macroscópicas.

2.2.2 Objetivos específicos

- Construir banco de imagens macroscópicas de madeiras da Caatinga;
- Testar a eficiência de YOLOv8 para a identificação/distinção de madeiras brasileiras com bancos dados de diferentes origens, equipamentos, magnificação e preparo de superfície.

2.3 REVISÃO DE LITERATURA

2.3.1 IDENTIFICAÇÃO DE MADEIRAS E ANÁLISE DE IMAGENS

Com a evolução dos recursos computacionais, o quantitativo exponencial de material a ser analisado e a necessidade de identificações acuradas e rápidas culminou nos estudos de técnicas para a identificação de madeiras utilizando novas tecnologias, especialmente com técnicas não destrutivas. Neste ínterim destaca-se o uso de identificação de madeiras por meio de imagens, área de estudo em que é mais comum o uso de classificadores baseados em textura, técnica que tem como fundamento a análise de padrões presentes nas imagens de seções transversais de madeira, possibilitando a distinção entre diferentes tipos (Wu et al., 2021). Portanto, assim como na técnica tradicional de identificação, o uso de classificadores baseados em textura também se fundamenta no reconhecimento de padrões, variando-se os algoritmos aplicados, o nível de tratamento das imagens e uma intrincada relação entre recursos estatísticos computacionais.

Mais recentemente, tem-se destacado a aplicação de recursos de inteligência artificial nesta área, sobressaindo-se o uso de técnicas de aprendizado profundo (*deep learning*). Por exemplo, Wu et al. (2021) testaram três CNNs (*ResNet-50*, *DenseNet-121* e *MobileNet-V2*) e alcançaram acurácia de 98,2% na classificação de madeiras de 11 espécies diferentes de folhosas. Por sua vez, Kwon et al. (2017) estudaram seis modelos *LeNet* e *MiniVGGNet* CNN para identificar cinco espécies de madeira de coníferas coreanas utilizando imagens macroscópicas, obtidas por câmera do iPhone 7, de superfícies serradas ásperas de seções transversais atingindo melhor acurácia de 99,3%. Zhao et al. (2021), desenvolveram uma arquitetura de rede neural convolucional (CNN) para a identificação de espécies raras alcançando acurácia de 99%.

Além da rapidez de processamento, os últimos estudos têm um foco na portabilidade, destacando-se o sistema *Xylotron*, que é um dispositivo desenvolvido especificamente para a identificação de madeira, combinando visão computacional, aprendizado de máquina, portabilidade e capacidade de identificação em tempo real, facilitando seu uso em campo, além de identificação baseada em informações espectrais (Ravindran et al., 2022ab; Ravindran,

Wiedenhoeft, 2022). Este sistema, que conta também com um *software* e dois modos de obtenção de imagens, tem ganhado cada vez mais relevância nos últimos anos, destacando-se as parcerias estabelecidas para a obtenção de imagens de espécies comercialmente relevantes, especialmente dos Estados Unidos e América do Sul (Arévalo et al., 2021).

No tocante aos recursos computacionais, destaca-se o uso de *transfer learning* e o processamento em nuvem, sendo o primeiro aplicável especialmente em conjuntos de dados limitados. Diversos métodos e algoritmos que utilizam *transfer learning* têm sido aplicados nas mais diversas áreas da Engenharia Florestal. Neste trabalho, será abordado o YOLO, algoritmo já utilizado na indústria madeireira para a detecção de defeitos em produtos madeiros (geralmente sólidos) na linha de produção, sendo, portanto, um instrumento para a indústria 4.0. Seu uso para identificação de madeiras ainda é pouco reportado e remete-se a versões anteriores, sendo o YOLOv8 a versão mais recente.

2.3.2 YOLOV8 (*You Only Look Once*, version 8)

De acordo com a *Ultralytics* (2023), o YOLOv8, abreviação de "*You Only Look Once version 8*", uma iteração avançada da série "*You Only Look Once*" de algoritmos de visão computacional, é um dos mais recentes desenvolvimentos em termos de algoritmos de detecção de objetos em imagens e vídeos, lançada em janeiro de 2023 pela empresa *Ultralytics*. Isso é possível graças à arquitetura baseada em redes neurais convolucionais profundas, que permite uma análise rápida e eficiente de imagens e vídeos. Além disso, o YOLOv8 suporta a detecção de múltiplos objetos em uma única imagem, o que o torna adequado para uma ampla gama de aplicações, desde vigilância de segurança, passando por detecção de incêndios, até reconhecimento de objetos em veículos autônomos. Os detalhes do YOLOv8, relatados na sequência, são descritos de acordo com a documentação fornecida pela *Ultralytics* (2023) disponível no período de construção deste estudo em seu site (<https://docs.ultralytics.com/>).

Um dos principais benefícios do YOLOv8 é sua velocidade de processamento quando comparado a outros algoritmos de detecção de objetos.

Isso é possível em razão da necessidade de uma única passagem dos dados pela rede, sendo eficiente e precisa na realização de tarefas, mesmo com alto grau de complexidade. Outro benefício importante é a facilidade de implementação, pois o YOLOv8 está disponível como uma estrutura de código aberto, permitindo adaptações e personalizações conforme necessário para atender às necessidades específicas de cada aplicação. Em contrapartida, a principal desvantagem é a necessidade de recursos computacionais significativos para operar de forma eficiente, o que pode limitar sua aplicabilidade em dispositivos com recursos limitados. Além dos benefícios supracitados, YOLOv8 é capaz de identificar múltiplos objetos em uma única imagem, fornecendo saídas precisas e detalhadas sobre as classes dos objetos presentes. Por fim, o YOLOv8 também apresenta robusto processamento para a tarefa de classificação de objetos em imagens.

Dentre as inúmeras ferramentas e modos disponíveis nesta versão do YOLO, destaca-se neste trabalho o *mosaic* e o *mixup* para fins de *data augmentation* (aumento de dados). *Mixup* é uma técnica de aumento de dados que envolve a combinação linear de dois exemplos de treinamento diferentes (imagens e suas anotações de caixas delimitadoras) e tem como objetivo criar uma nova imagem composta que herda características de ambas as imagens originais. Isso é feito através de uma equação onde os pixels das duas imagens são misturados, assim como suas respectivas etiquetas (*labels*). A mistura é regulada por um parâmetro λ que é escolhido aleatoriamente de uma distribuição *Beta*. Sua aplicação auxilia o modelo a lidar melhor com ambiguidades e a entender variações sutis nos objetos. Por sua vez, o *mosaic* combina quatro imagens diferentes em uma única imagem de treinamento. As imagens são redimensionadas e colocadas juntas, formando uma colagem que contém partes de cada uma das quatro imagens. Isso não apenas aumenta a diversidade das amostras de treinamento, mas também força o modelo a aprender a identificar e localizar objetos em cenários mais complexos e lotados, onde múltiplos objetos podem estar parcialmente obscurecidos ou sobrepostos.

A aplicação do YOLO na qualidade da madeira é mais extensa na sua terceira versão (YOLOv3), com estudos voltados para a identificação de defeitos na superfície da madeira para fins de controle de qualidade (Cui et al, 2023; Kurdthongmee, 2020; Lopes et al., 2020; Wang et al., 2021), assim como o

YOLOv5 para os mesmos fins (Fang et al., 2021; Haonan et al., 2023; Meng, Yuan, 2023; Wang et al., 2021; Zhang et al., 2023; Zheng, 2024;). Com pouco mais de um ano de seu lançamento, o YOLOv8 também já possui aplicações na área, como detecção de defeitos em madeira (An et al., 2024; Wang et al., 2023; Zhou et al., 2024;) e contagem de toras empilhadas (Casas et al., 2023). Para a identificação de madeiras, cita-se o *conference paper* de autoria de Rosli et al. (2021) que utilizou YOLOv3 para a identificação de madeiras tropicais de dez espécies distintas, alcançando acurácia entre 65% e 98%.

2.4 METODOLOGIA

2.4.1 BANCOS DE DADOS

Foram performados 4 testes usando aprendizado de máquina e diferentes bancos de dados (*datasets*) de imagens em diferentes combinações (Tabela 1).

As informações de cada banco de dados são descritas nos tópicos seguintes. O banco de dados Caatinga (banco de dados 1) é de autoria própria, enquanto os demais são de domínio público, *Forest Species Database – Macroscopic (FSD-M)*, *Endangered Forest Species (EFS)* e Polícia Federal (PF) ou cedidos após autorização do autor (Mata Atlântica, banco de dados 2). Os bancos de dados que não são de autoria própria passaram por uma triagem em que as classes com quantidade de imagens igual ou menor que 10 foram eliminadas. As pranchas contendo as imagens de cada espécie de todos os bancos de dados utilizados estão no Anexo I. Os procedimentos computacionais empregados em cada teste foram os mesmos e estão descritos no tópico “Visão Computacional”.

TABELA 1 – RELAÇÃO DE TESTES, COMBINAÇÕES DE BANCO DE DADOS E RESPECTIVOS NÚMEROS DE IMAGENS

Teste	Combinação	Número de imagens
1	Banco de dados 1	3.538
2	Banco de dados 2	2.002
3	Banco de dados 1 + 2	5.540
4 e 5	Banco de dados 1+2+ FSD-M+EFS+PF	10.578

FONTE: A autora (2024).

2.4.1.1 Banco de dados 1 – Caatinga (autoria própria)

A coleta das árvores foi realizada entre julho e agosto de 2019 na Fazenda Riacho do Cabra (06°13'44,4"S 36°01'22,8"O), município de Santa Cruz (Mesorregião do Agreste Potiguar e microrregião da Borborema Potiguar), estado do Rio Grande do Norte, localizado na região nordeste do Brasil. A área é caracterizada por vegetação caatinga (savana-estépica), o clima segundo Köppen é do tipo BSs'h', semiárido com precipitação menor que a evaporação e

a estação chuvosa no outono, possuindo assim clima seco acentuado em média por 6 meses.

Foram coletadas amostras do tronco com 15 cm de comprimento em seis alturas do fuste comercial: DAP (1,30 acima do nível do solo), 0% (10 cm acima do nível do solo), 25%, 50%, 75% e 100% por árvore de sete espécies previamente selecionadas (Tabela 2). O material foi coletado de três árvores por espécie, seco ao ar livre e posteriormente transportado para o Laboratório de Anatomia e Qualidade da Madeira (LANAQM) na Universidade Federal do Paraná (UFPR). O material genético coletado está registrado no Sistema Nacional de Gestão do Patrimônio Genético (SisGen) sob o número A432EB4.

TABELA 2 – RELAÇÃO DE ESPÉCIES BANCO DE DADOS CAATINGA

Nome científico	Nome popular	Família	n
<i>Aspidosperma pyrifolium</i> Mart. & Zucc.	Pereiro	Apocynaceae	414
<i>Capparidastrium frondosum</i> (Jacq.) Cornejo & Iltis	Feijão Bravo	Capparaceae	401
<i>Manihot baccata</i> Allem	Maniçoba	Euphorbiaceae	381
<i>Anadenanthera colubrina</i> (Vell.) Brenan	Angico	Fabaceae	563
<i>Cenostigma pyramidale</i> (Tul.) Gagnon & G. P. Lewis	Catingueira	Fabaceae	532
<i>Mimosa tenuiflora</i> (Willd.) Poir.	Jurema Preta	Fabaceae	521
<i>Guapira</i> sp.	Pau Mole	Nyctaginaceae	726

FONTE: A autora (2024).

LEGENDA: n = número de imagens de cada espécie.

O material foi posteriormente seccionado em discos com espessuras distintas com serra de fita na marcenaria do Departamento de Tecnologia e Engenharia Florestal da UFPR. Um disco do DAP foi destinado para a confecção de amostras para a identificação anatômica microscópica, enquanto outro disco de DAP e três discos de cada um das demais alturas (totalizando 16 discos por árvore) foram destinados para a obtenção de fotografias após homogeneização da superfície. A superfície transversal dos discos foi polida usando uma lixadeira elétrica e lixas de diversas gramaturas em numeração crescente (40, 80, 120, 180 e 320). A identificação das espécies foi realizada por meio da observação de caracteres macroscópicos e microscópicos e consequente comparação com indivíduos da coleção do LANAQM e *Inside Wood* (2004).

A face transversal lixada foi utilizada para a aquisição das imagens pela autora desta tese. Essa superfície foi fotografada, evitando-se ao máximo ocos, rachaduras, manchas e outros defeitos, contudo, em algumas imagens não foi possível excluir tais áreas. Para assegurar a não repetição de um mesmo trecho da madeira, utilizou-se de um gabarito com dimensões internas aproximadas de 2,3 cm de comprimento por 1,7 cm de altura. Portanto, para a obtenção de uma imagem, o gabarito era posicionado e sua delimitação delineada com lapiseira grafite HB e a imagem era então enquadrada dentro desta delimitação. Posteriormente, a imagem seguinte era obtida posicionando o gabarito ao lado da delimitação, evitando a sobreposição de áreas. A maior parte das imagens obtidas foi devidamente alinhada com os raios e parênquima axial, enquanto outras não obedeceram a esta ordenação, atribuindo assim maior variação ao banco.

Para aquisição das imagens foi utilizado um smartphone Motorola One Fusion Plus e uma lente macro (com aumento de 10x) da marca Apexel (modelo APL-HB10X) acoplada à câmera principal do aparelho celular. Além do aumento oferecido pela lente macro, adicionou-se mais 2x *zoom* pelo aplicativo de captura de imagens do próprio celular, mantendo-se as demais configurações automáticas (Quadro 1). As imagens foram obtidas no formato JPEG.

QUADRO 1 – INFORMAÇÕES SOBRE A CÂMERA E AQUISIÇÃO DE IMAGENS

Zoom 2x (+lente macro de 10x)	Abertura focal: f/1.8
Câmera de 64MP	Tempo de exposição: 1/20s 1/30s
Sistema operacional: Android	ISSO: variável
Resolução (altura x largura) 3472 x 4640 pixels	Distância focal: 6mm
Resolução: 72dpi	Abertura máxima 1.69
Representação de cores sRGB	Formato de arquivo: JPEG

FONTE: A autora (2024).


As fotos foram obtidas dentro do Laboratório de Anatomia e Qualidade da Madeira da Universidade Federal do Paraná. As imagens tiveram como fonte de luz as lâmpadas fluorescentes fixadas no teto do laboratório e a iluminação natural (que variou ao decorrer dos meses). O celular (com lente macro acoplada) foi posicionado acima das amostras utilizando um suporte, mantendo

uma distância aproximada de 2,8cm entre a lente a superfície da amostra. Foram coletadas 2875 imagens, sendo variável o número de imagens de cada espécie em função do diâmetro e condições sanitárias de cada uma (Tabela 2).

2.4.1.2 Banco de dados 2 – Mata Atlântica (Andrade; Basso; Latorraca, 2020)

Este banco de dados foi obtido por Andrade, Basso e Latorraca (2020) usando um smartphone (Motorola G5) e uma caixa acoplada contendo uma lente macro e uma fonte de luz LED, mantendo as amostras a uma distância fixa (aproximadamente 1,5cm) (Figura 13). De acordo com o estudo supracitado, a superfície das amostras foi umedecida e em seguida cortada usando uma faca para simular procedimentos utilizados em identificação em campo. O estudo compreende 21 espécies da Mata Atlântica, totalizando 2002 imagens do plano transversal (Tabela 3). Mais detalhes podem ser conferidos em Andrade, Basso e Latorraca (2020), assim como no trabalho de Andrade (2020). Este é o banco de dado utilizado isoladamente no Teste 2.

FIGURA 13 – SISTEMA DE OBTENÇÃO DE IMAGENS



FONTE: ANDRADE; BASSO; LATORRACA (2020).

TABELA 3 – RELAÇÃO DE ESPÉCIES E RESPECTIVAS INFORMAÇÕES DO BANCO DE DADOS MATA ATLÂNTICA (ANDRADE; BASSO; LATORRACA, 2020)

Espécie	Nome popular*	Família	n
<i>Astronium concinnum</i> (Engl.) Schott	Aroeira-rajada	Anacardiaceae	109
<i>Astronium graveolens</i> Jacq.	Guarítá	Anacardiaceae	92
<i>Aspidosperma pyricollum</i> Müll. Arg.	Pequiá-amarelo	Apocynaceae	128
<i>Handroanthus serratifolius</i> (Vahl.) S.O. Grose	Ipê	Bignoniaceae	73
<i>Cordia trichotoma</i> (Vell.) Arráb. Ex Stend.	Freijó	Cordiaceae	70
<i>Terminalia mameluco</i> Pickel	Pequi-doce	Combretaceae	106
<i>Amburana cearensis</i> (Allemão) A.C. Sm.	Imburana de cheiro	Fabaceae	82
<i>Bowdichia virgilioides</i> Kunth.	Sucupira	Fabaceae	87
<i>Senegalia polyphylla</i> (DC.) Britton & Rose	Guarucuia	Fabaceae	100
<i>Tachigali vulgaris</i> L.F. Gomes da Silva & H.C. Lima	Tachi-branco	Fabaceae	79
<i>Paubrasilia echinata</i> (Lam.) Gagnon, H.C. Lima & G.P. Lewis	Pau-brasil	Fabaceae	85
<i>Copaifera lucens</i> Dwyer	Pau-óleo	Fabaceae	83
<i>Barnebydendron riedelii</i> (Tul.) J.H. Kirkbr.	Guarabu	Fabaceae	100
<i>Dalbergia nigra</i> (Vell.) Allemão ex Benth.	Jacarandá-da-bahia	Fabaceae	123
<i>Anadenanthera peregrina</i> (L.) Spig.	Angico-branco	Fabaceae	102
<i>Parapiptadenia pterosperma</i> (Benth.) Brenan	Angico-roxo	Fabaceae	109
<i>Plathymenia foliolosa</i> Benth. (<i>Plathymenia reticulata</i> Benth.)	Vinhático	Fabaceae	88
<i>Cariniana legalis</i> (Mart.) Kuntze	Jequitibá	Lecythidaceae	151
<i>Lecythis pisonis</i> Cambess.	Sapucaia	Lecythidaceae	111
<i>Pterygota brasiliensis</i> Allemão	Pau-rei	Malvaceae	92
<i>Manilkara</i> sp.	Maçaranduba	Sapotaceae	80

FONTE: Adaptado de Andrade, Basso e Latorraca (2020).

LEGENDA: n: número de imagens.

As configurações da câmera foram ISO 100, balanço de branco no modo de luz diurna e zoom 4x, enquanto os demais parâmetros foram mantidos em modo automático. As imagens produzidas tem 2448 x 3264 pixels (8bits, 256 níveis de cinza) e área aproximada de 4,5 mm x 6 mm. As imagens foram obtidas durante o dia, em área externa e sombreada. Os autores definiram um padrão de obtenção das imagens começando próximo à casca em uma extremidade até a extremidade oposta da amostra, cobrindo toda a superfície transversal sem sobreposição de áreas e evitando defeitos.

2.4.1.3 Banco de dados 3 – Miscelânea (Paula Filho et al., 2014; Souza et al., 2020; *Dataset* Polícia Federal)

1) *Forest Species Database – Macroscopic* (FSD-M) (Paula Filho et al., 2014)

O banco de dados denominado como *Forest Species Database – Macroscopic* (FSD-M), compreende 41 espécies arbóreas brasileiras (Tabela 4), totalizando 2.942 imagens macroscópicas da face transversal dos espécimes (Paula Filho et al., 2014). A superfície transversal das amostras foi lixada usando lixas de 80 e 320 de gramatura, exceto para *Aspidosperma polyneuron*, *Goupia glabra* e *Micropholis venulosa*, que foram preparados usando navalha em micrótomo de deslize.

As imagens foram obtidas com uma câmera Sony DSC T20, com a função macro ativada, posicionada perpendicularmente à amostra dentro de uma caixa de madeira com duas lâmpadas de halogênio posicionadas nas laterais. A amostra é posicionada no fundo do caixa, mantendo-se uma distância fixa em relação à câmera de aproximadamente 1cm. A organização do sistema (Figura 14) e a disposição das fontes fornecem luz indireta e destaca as características da amostra. As imagens resultantes tinham resolução de 3264 × 2448 pixels e formato JPG. O banco de dados está disponível em: <https://zenodo.org/records/10219797>. Todos os indivíduos foram cientificamente identificados por anatomista. Ademais, houve atualização de uma das espécies de acordo com o site Flora e Funga do Brasil (JBRJ, 2024), portanto, a nova denominação foi inserida entre parênteses ao lado da denominação utilizada originalmente por Paula Filho et al. (2014).

TABELA 4 – RELAÇÃO DE ESPÉCIES E RESPECTIVAS INFORMAÇÕES DO BANCO DE DADOS *FOREST SPECIES DATABASE – MACROSCOPIC* (PAULA FILHO et al., 2014)

Nome científico	Nome comum	Família	n
<i>Aspidosperma polyneuron</i> Müll. Arg.	Peroba rosa	Apocynaceae	43
<i>Araucaria angustifolia</i> (Bertol.) Kuntze	Araucária	Araucariaceae	63
<i>Tabebuia</i> sp.	ipê	Bignoniaceae	99
<i>Cordia goeldiana</i> Huber	Freijó	Boraginaceae	53
<i>Cordia</i> sp.	Louro	Boraginaceae	51
<i>Hura crepitans</i>	Assacu	Euphorbiaceae	41
<i>Acrocarpus fraxinifolius</i> Arn	Acrocarpus	Fabaceae	53
<i>Bowdichia</i> sp.	Sucupira	Fabaceae	99
<i>Cedrelinga cateniformis</i> (Ducke) Ducke	Cedrorana	Fabaceae	99
<i>Dipteryx</i> sp.	Cumarú	Fabaceae	67
<i>Hymenaea</i> sp.	Jatobá	Fabaceae	82
<i>Hymenolobium petraeum</i> Ducke	Angelim-pedra	Fabaceae	99
<i>Machaerium</i> sp.	Caviúna	Fabaceae	87
<i>Mimosa scabrella</i> Benth.	Bracatinga	Fabaceae	48
<i>Myroxylon balsamum</i> (L.) Harms	Pau-de-bálsamo	Fabaceae	75
<i>Peltogyne</i> sp.	Roxinho	Fabaceae	58
<i>Goupia glabra</i> Aubl.	Cupiúba	Goupiaceae	51
<i>Laurus nobilis</i> L.	Louro	Lauraceae	46
<i>Mezilaurus itauba</i> (Meisn.) Taub. Ex Mez	Itaúba	Lauraceae	64
<i>Ocotea porosa</i> (Nees & Mart.) Barroso	Imbuia	Lauraceae	99
<i>Bertholletia excelsa</i> Bonpl.	Castanheira	Lecythidaceae	72
<i>Cariniana estrellensis</i> (Raddi) Kuntze	Jequitibá-branco	Lecythidaceae	55
<i>Couratari</i> sp.	Tauari	Lecythidaceae	63
<i>Carapa guianensis</i> Aubl.	Andiroba	Meliaceae	43
<i>Cedrela fissilis</i> Vell.	Cedro	Meliaceae	37
<i>Melia azedarach</i> L.	Cinamomo	Meliaceae	56
<i>Swietenia macrophylla</i> King	Mogno	Meliaceae	96
<i>Bagassa guianensis</i> Aubl.	Tatajuba	Moraceae	58
<i>Brosimum paraense</i> (<i>Brosimum rubescens</i> Taub.)	Muirapiranga	Moraceae	63
<i>Virola surinamensis</i> (Rol. ex Rottb.) Warb.	Virola	Myristicaceae	80
<i>Eucalyptus</i> sp.	Eucalipto	Myrtaceae	99
<i>Pinus</i> sp.	Pinus	Pinaceae	79
<i>Podocarpus lambertii</i> Kl.	Pinheiro-bravo	Podocarpaceae	62
<i>Grevillea robusta</i> A. Cunn. Ex R. Br.	Grevílea	Proteaceae	86
<i>Balfourodendron riedelianum</i> (Engl.) Engl.	Pau-marfim	Rutaceae	99
<i>Euxylophora paraensis</i> Huber	Pau-amarelo	Rutaceae	96
<i>Manilkara elata</i> (Allemão ex Miq.) Monach	Maçaranduba	Sapotaceae	92
<i>Micropholis venulosa</i> (Mart. & Eichler) Pierre	Curupixá	Sapotaceae	78
<i>Pouteria pachycarpa</i> Pires	Goiabão	Sapotaceae	94
<i>Erismia uncinatum</i> Warm.	Cedrinho	Vochysiaceae	98
<i>Vochysia</i> sp.	Quaruba	Vochysiaceae	59

FONTE: Adaptado de Paula Filho et al. (2014). LEGENDA: n: número de imagens.

FIGURA 14 – SISTEMA PARA OBTENÇÃO DE IMAGENS



FONTE: Adaptado de Paula Filho et al. (2014).

2) *Endangered Forest Species* (SOUZA et al., 2020)

O banco de dados denominado como *Endangered Forest Species* (Souza et al., 2020) é composto por 46 espécies arbóreas brasileiras (Tabela 5), totalizando 1.901 imagens macroscópicas da face transversal dos espécimes. As amostras foram previamente lixadas com lixa de grão 120 e imagens adquiridas usando um estereomicroscópio *Zeiss Discovery V 12* e magnificação de 10x, com imagens de resolução 2080 × 1540 pixels e 150 dpi. O banco de dados está disponível em: <https://data.mendeley.com/datasets/cc78ftcdf9/1>. Todos os espécimes foram devidamente identificados por anatomista.

TABELA 5 – RELAÇÃO DE ESPÉCIES E RESPECTIVAS INFORMAÇÕES DO BANCO DE DADOS *ENDANGERED FOREST SPECIES* (Souza et al., 2020) (CONTINUA)

Nome científico	Nome comum	Família	n
<i>Aspidosperma</i> sp.	Peroba	Apocynaceae	41
<i>Aspidosperma polyneuron</i> Müll. Arg.	Peroba rosa	Apocynaceae	20
<i>Araucaria angustifolia</i> (Bertol.) Kuntze	Araucária	Araucariaceae	55
<i>Handroanthus</i> sp.	Ipê	Bignoniaceae	33
<i>Cordia goeldiana</i> Huber	Freijó	Boraginaceae	36
<i>Acrocarpus fraxinifolius</i> Arn.	Cedro rosa	Fabaceae	17
<i>Bowdichia</i> sp.	Sucupira	Fabaceae	68

TABELA 5 – RELAÇÃO DE ESPÉCIES E RESPECTIVAS INFORMAÇÕES DO BANCO DE DADOS *ENDANGERED FOREST SPECIES* (Souza et al., 2020) (FINAL)

Nome científico	Nome comum	Família	n
<i>Cedrelinga cateniformis</i> (Ducke) Ducke	Cedrorana	Fabaceae	65
<i>Dipteryx</i> sp.	Cumarú	Fabaceae	27
<i>Hymenaea</i> sp.	Jatobá	Fabaceae	32
<i>Hymenolobium petraeum</i> Ducke	Angelim-pedra	Fabaceae	28
<i>Hymenolobium</i> sp.	Angelim	Fabaceae	28
<i>Inga vera</i> Willd.	Ingá	Fabaceae	40
<i>Machaerium paraguariense</i> Hassl.	Jacarandá	Fabaceae	37
<i>Machaerium</i> sp.	Caviúna	Fabaceae	15
<i>Mimosa scabrella</i> Benth.	Bracatinga	Fabaceae	30
<i>Muelleria paraenses</i> (Mart. Ex Benth.) M.J. Silva & A.M.G. Azevedo	Jacarandá-branco	Fabaceae	39
<i>Myroxylon balsamum</i> (L.) Harms	Pau-de-bálsamo	Fabaceae	53
<i>Peltogyne</i> sp.	Roxinho	Fabaceae	30
<i>Goupia glabra</i> Aubl.	Cupiúba	Goupiaceae	32
<i>Laurus nobilis</i> L.	Louro	Lauraceae	36
<i>Mezilaurus itauba</i> (Meisn.) Taub. Ex Mez	Itaúba	Lauraceae	83
<i>Nectandra megapotamica</i> (Spreng.) Mez	Canela-imbuia	Lauraceae	28
<i>Ocotea indecora</i> (Schott) Mez	Canela	Lauraceae	36
<i>Ocotea porosa</i> (Nees & Mart.) Barroso	Imbuia	Lauraceae	46
<i>Bertholletia excelsa</i> Bonpl.	Castanheira	Lecythidaceae	35
<i>Cariniana estrellensis</i> (Raddi) Kuntze	Jequitibá-branco	Lecythidaceae	36
<i>Couratari</i> sp.	Tauari	Lecythidaceae	41
<i>Carapa guianensis</i> Aubl.	Andiroba	Meliaceae	21
<i>Cedrela fissilis</i> Vell.	Cedro	Meliaceae	22
<i>Melia azedarach</i> L.	Cinamomo	Meliaceae	47
<i>Swietenia macrophylla</i> King	Mogno	Meliaceae	70
<i>Bagassa guianensis</i> Aubl.	Tatajuba	Moraceae	52
<i>Brosimum parinarioides</i> Ducke	Muirapiranga	Moraceae	25
<i>Eucalyptus</i> sp.	Eucalipto	Myrtaceae	27
<i>Eugenia pyriformis</i> Cambess.	Uvaia	Myrtaceae	35
<i>Pinus</i> sp.	Pinus	Pinaceae	42
<i>Grevillea robusta</i> A. Cunn. Ex R. Br.	Grevilea	Proteaceae	48
<i>Balfourodendron riedelianum</i> (Engl.) Engl.	Pau-marfim	Rutaceae	61
<i>Euxylophora paraensis</i> Huber	Pau-amarelo	Rutaceae	66
<i>Manilkara elata</i> (Allemão ex Miq.) Monach.	Maçaranduba	Sapotaceae	39
<i>Micropholis venulosa</i> (Mart. & Eichler) Pierre	Abiu	Sapotaceae	71
<i>Pouteria pachycarpa</i> Pires	Goiabão	Sapotaceae	47
<i>Simarouba amara</i> Aubl.	Marupá	Simaroubaceae	30
<i>Erisma uncinatum</i> Warm.	Cedrinho	Vochysiaceae	58
<i>Vochysia</i> sp.	Quaruba	Vochysiaceae	43

FONTE: Adaptado de Souza et al. (2020).

LEGENDA: n: número de imagens.

3) PF e Combinação miscelânea

Este banco de dados é uma combinação de todos os bancos de dados anteriores e um banco de dados fornecido pela Polícia Federal brasileira com imagens de espécies amazônicas (imagens não previamente identificadas por anatomistas, mas sim por funcionários da fiscalização previamente treinados e com experiência, que também forneceram os respectivos nomes vernaculares). Esse banco ainda está em construção e é objetivo da PF que sua atualização se mantenha de forma contínua.

As imagens fornecidas pela PF foram obtidas usando microscópio USB digital com mesma magnificação (não informada) e a superfície das amostras foi preparada apenas com o uso de objeto cortante. Esse banco se tornará público em um futuro próximo e foi obtido para realização deste estudo por meio de solicitação prévia. Os nomes científicos foram verificados e corrigidos quando necessários quanto à ortografia e adicionados os nomes aceitos e corretos (entre parênteses) de acordo com o site Flora e Funga do Brasil (JBRJ, 2024).

Como havia uma grande variedade no número de imagens por classe fornecidas pela PF, estabeleceu-se que, para entrar neste estudo, cada classe precisava apresentar no mínimo 50 imagens. A Tabela 6 lista a combinação de todos os bancos de dados, totalizando 71 classes (espécies + amostras identificadas apenas a nível de gênero) e 10.578 imagens.

TABELA 6 – RELAÇÃO DE ESPÉCIES E RESPECTIVAS INFORMAÇÕES DO BANCO DE DADOS RESULTANTE DA COMBINAÇÃO DE TODOS OS BANCOS (CONTINUA)

Nome científico	Nome popular	Família	n
<i>Acrocarpus fraxinifolius</i> Arn.	Cedro rosa	Fabaceae	92
<i>Amburana cearensis</i> (Allemão) A.C. Sm.	Imburana de cheiro	Fabaceae	79
<i>Anadenanthera colubrina</i> (Vell.) Brenan	Angico	Fabaceae	563
<i>Anadenanthera peregrina</i> (L.) Speg.	Angico-branco	Fabaceae	102
<i>Apuleia leiocarpa</i> (Vogel) J.F.Macbr.	Peroba-mico	Apocynaceae	50
<i>Araucaria angustifolia</i> (Bertol.) Kuntze	Araucária	Araucariaceae	166
<i>Aspidosperma polyneuron</i> Müll. Arg.	Peroba rosa	Apocynaceae	66
<i>Aspidosperma pyricollum</i> Müll. Arg.	Pequiá-amarelo	Apocynaceae	125
<i>Aspidosperma pyriformium</i> Mart. & Zucc.	Pereiro	Apocynaceae	414
<i>Aspidosperma</i> sp.	Peroba	Apocynaceae	68
<i>Astronium concinnum</i> (Engl.) Schott	Aroeira-rajada	Anacardiaceae	85

TABELA 6 – RELAÇÃO DE ESPÉCIES E RESPECTIVAS INFORMAÇÕES DO BANCO DE DADOS RESULTANTE DA COMBINAÇÃO DE TODOS OS BANCOS (CONTINUA)

<i>Astronium graveolens</i> Jacq.	Guaritá	Anacardiaceae	86
<i>Bagassa guianensis</i> Aubl.	Tatajuba	Moraceae	144
<i>Balfourodendron riedelianum</i> (Engl.) Engl.	Pau-marfim	Rutaceae	171
<i>Barnebydendron riedelii</i> (Tul.) J.H. Kirkbr.	Guarabu	Fabaceae	100
<i>Bertolletia excelsa</i> Bonpl.	Castanheira	Lecythidaceae	187
<i>Bowdichia</i> sp.	Sucupira	Fabaceae	194
<i>Bowdichia virgilioides</i> Kunth.	Sucupira	Fabaceae	85
<i>Brosimum paraensis</i> (<i>Brosimum rubescens</i> Taub.)	Muirapiranga	Moraceae	161
<i>Capparidastrum frondosum</i> (Jacq.) Cornejo & Iltis	Feijão Bravo	Capparaceae	401
<i>Carapa guianensis</i> Aubl.	Andiroba	Meliaceae	76
<i>Cariniana estrellensis</i> (Raddi) Kuntze	Jequitibá-branco	Lecythidaceae	98
<i>Cariniana legalis</i> (Mart.) Kuntze	Jequitibá-rosa	Lecythidaceae	151
<i>Cedrela fissilis</i> Vell.	Cedro	Meliaceae	69
<i>Cedrelinga cateniformis</i> (Ducke) Ducke	Cedrorana	Fabaceae	358
<i>Cenostigma pyramidale</i> (Tul.) Gagnon & G. P. Lewis	Catingueira	Fabaceae	532
<i>Clarisia racemosa</i> Ruiz & Pav.	Guariúba	Moraceae	51
<i>Copaifera lucens</i> Dwyer	Pau-óleo	Fabaceae	83
<i>Cordia alliodora</i> (Ruiz & Pav.) Cham.	Freijó	Cordiaceae	51
<i>Cordia goeldiana</i> Huber	Freijó	Cordiaceae	130
<i>Cordia trichotoma</i> (Vell.) Arráb. Ex Stend.	Freijó	Cordiaceae	70
<i>Couratari</i> sp.	Tuari	Lecythidaceae	120
<i>Dalbergia nigra</i> (Vell.) Allemão ex Benth.	Jacarandá-da-bahia	Fabaceae	123
<i>Dipteryx</i> sp.	Cumarú	Fabaceae	129
<i>Erismia uncinatum</i> Warm.	Quaruba	Vochysiaceae	181
<i>Eucalyptus</i> sp.	Eucalipto	Myrtaceae	149
<i>Euxylophora paraensis</i> Huber	Pau-amarelo	Rutaceae	182
<i>Goupia glabra</i> Aubl.	Cupiúba	Goupiaceae	91
<i>Grevilea robusta</i> A. Cunn. Ex R. Br	Grevilea	Proteaceae	136
<i>Guapira</i> sp.	Pau Mole	Nyctaginaceae	63
<i>Handroanthus serratifolius</i> (Vahl.) S.O. Grose	Ipê	Bignoniaceae	71
<i>Handroanthus</i> sp.	Ipê	Bignoniaceae	149
<i>Hymenaea</i> sp.	Jatobá	Fabaceae	152
<i>Hymenolobium petraeum</i> Ducke	Angelim pedra	Fabaceae	231

TABELA 6 – RELAÇÃO DE ESPÉCIES E RESPECTIVAS INFORMAÇÕES DO BANCO DE DADOS RESULTANTE DA COMBINAÇÃO DE TODOS OS BANCOS (FINAL)

<i>Laurus nobilis</i> L.	Louro	Lauraceae	86
<i>Lecythis pisonis</i> Cambess.	Sapucaia	Lecythidaceae	111
<i>Machaerium</i> sp.	Caviúna	Fabaceae	102
<i>Manihot baccata</i> Allem	Maniçoba	Euphorbiaceae	381
<i>Manilkara huberi</i> (Ducke) A.Chev. (<i>Manilkara elata</i> (Allemão ex Miq.))	Maçaranduba	Sapotaceae	141
<i>Manilkara</i> sp.	Maçaranduba	Sapotaceae	78
<i>Melia azedarach</i> L.	Cinamomo	Meliaceae	146
<i>Mezilaurus itauba</i> (Meisn.) Taub. Ex Mez	Itaúba	Lauraceae	151
<i>Micropholis venulosa</i> (Mart. & Eichler) Pierre	Curupixá	Sapotaceae	160
<i>Mimosa scabrella</i> Benth.	Bracatinga	Fabaceae	89
<i>Mimosa tenuiflora</i> (Willd.) Poir.	Jurema Preta	Fabaceae	521
<i>Myroxylon balsamum</i> (L.) Harms	Pau-de-bálsamo	Fabaceae	139
<i>Ocotea porosa</i> (Nees & Mart.) Barroso	Imbuia	Lauraceae	160
<i>Parapiptadenia pterosperma</i> (Benth.) Brenan	Angico-roxo	Fabaceae	107
<i>Paubrasilia echinata</i> (Lam.) Gagnon, H.C. Lima & G.P. Lewis	Pau-brasil	Fabaceae	84
<i>Peltogyne</i> sp.	Roxinho	Fabaceae	120
<i>Pinus</i> sp.	Pinus	Pinaceae	127
<i>Podocarpus lambertii</i> Kl.	Pinheiro-bravo	Podocarpaceae	62
<i>Pouteria pachycarpa</i> Pires	Goiabão	Sapotaceae	146
<i>Pterygota brasiliensis</i> Allemão	Pau-rei	Malvaceae	92
<i>Senegalia polyphylla</i> (DC.) Britton & Rose	Guarucuia	Fabaceae	102
<i>Simarouba amara</i> Aubl	Marupá	Simaroubaceae	84
<i>Swietenia macrophylla</i> King	Mogno	Meliaceae	228
<i>Tachigali vulgaris</i> L.F. Gomes da Silva & H.C. Lima	Tachi-branco	Fabaceae	79
<i>Terminalia mameluco</i> Pickel	Pequi-doce	Combretaceae	105
<i>Virola surinamensis</i> (Rol. ex Rottb.) Warb	Virola	Myristicaceae	80
<i>Vochysia</i> sp.	Quaruba	Vochysiaceae	112

FONTE: A autora (2024).

2.4.2 VISÃO COMPUTACIONAL

O processamento foi realizado com YOLOv8.0.203 (*Ultralytics*) (Jocher; Chaurasia; Qiu, 2023), *Python*-3.10.12 e *torch*-2.0.1+cu117 com CUDA NVIDIA

GeForce RTX 4070 Ti, 12281MiB (Quadro 2). A escala utilizada foi a média (YOLOv8m) com especificações presentes no Quadro 3 para o modo de classificação (YOLOv8m-cls).

QUADRO 2 – ESPECIFICAÇÕES DA PLACA DE VÍDEO CUDA NVIDIA GeForce RTX 4070 Ti

Núcleos NVIDIA CUDA	7680
Boost Clock (GHz)	2,61
Tamanho da memória	12GB
Tipo de memória	GDDR6X

FONTE: NVIDIA.

QUADRO 3 – ESPECIFICAÇÕES DA YOLOV8M

	YOLOv8m
Tamanho (pixels)	224
acc top1	76,4
acc top 5	93,2
Velocidade CPU ONNX (ms)	85,4
Velocidade A100 TensorRT (ms)	0,62
Parâmetros (M)	17,0
FLOPs (G)	78,9
d (depth_multiple)	0,67
w (width_multiple)	0,75

FONTE: *Ultralytics* (2023) e *RangeKing* (2023).

LEGENDA: acc: acurácia baseada na validação usando o banco de dados da *ImageNet*; velocidade baseada na validação usando *ImageNet* e *Amazon EC2 P4d instance*.

A arquitetura de YOLOv8 é descrita na Figura 15.

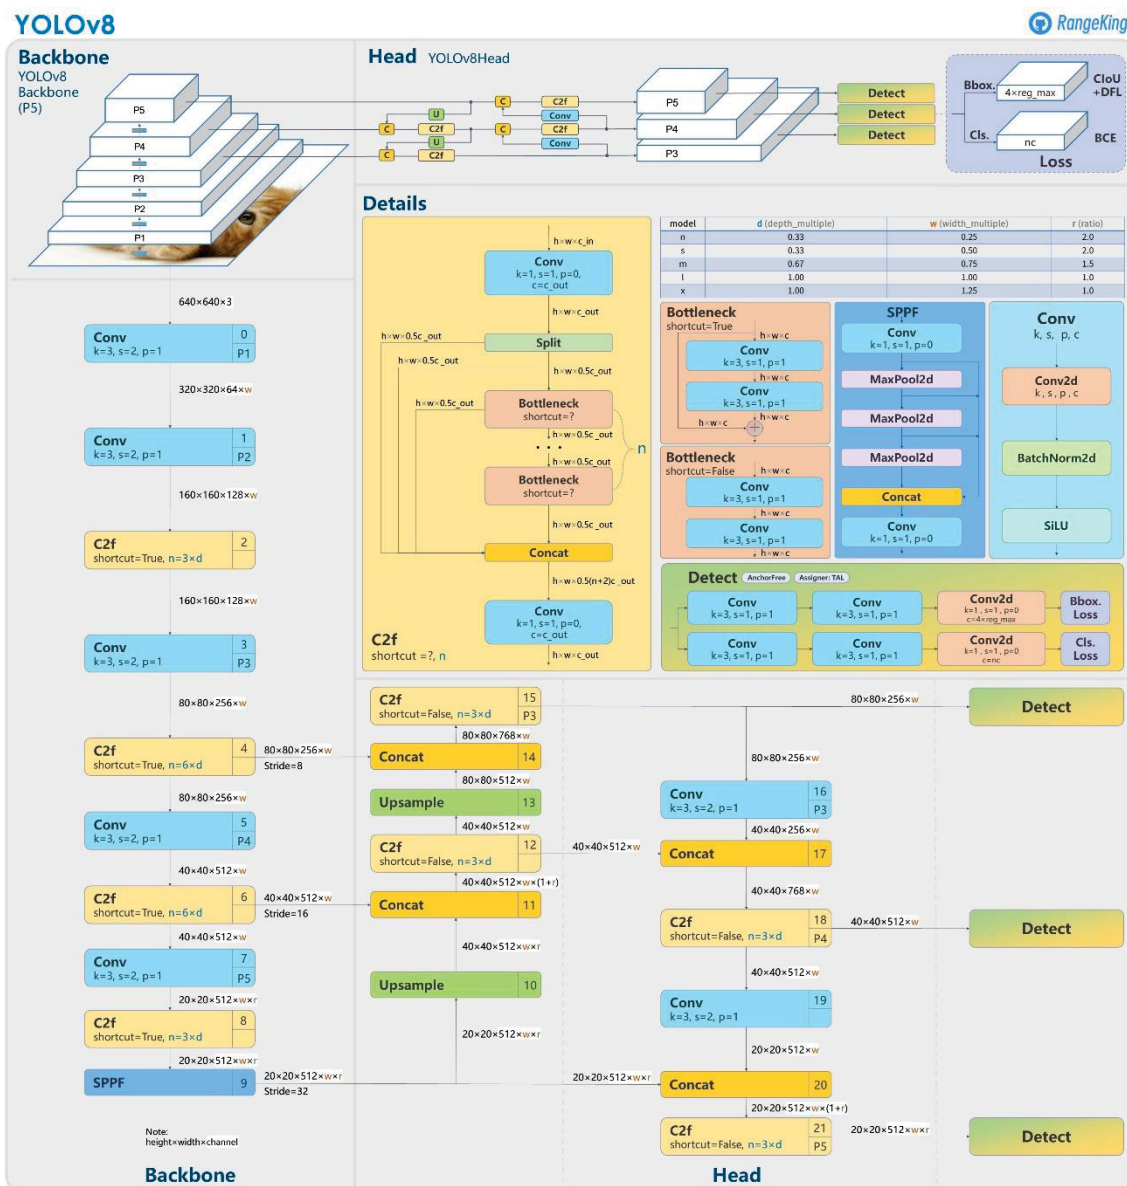
A estrutura central da rede neural está em *transfer learning* pois a YOLOv8 foi pré-treinada com o banco de dados *ImageNet* para a tarefa de classificação (Ultralytics, 2023). A função de ativação usada na arquitetura para as camadas convolucionais é a *Sigmoid Linear Units* (SiLU):

$$\text{silu}(x) = x * \sigma(x)$$

onde $\sigma(x)$ é o logistic sigmoid.

Mais informações a respeito dessa função de ativação podem ser encontradas em Elfwing et al. (2018) e Tsang (2022).

FIGURA 15 – ARQUITETURA DA YOLOV8



FONTE: RangeKing (2023).

LEGENDA: s: *sampling*; k: *kernel*; p: *pooling*; P1-P5: camadas de expressão de características; Conv: camada convolucional; C2f: *Coarse to fine*; *backbone*: “espinha dorsal”, parte central da arquitetura; SPPF: *spatial pyramid poolingfast*; Concat: camada de concatenação.

2.4.2.1 Preparação dos Dados - Pré-processamento

Todas as imagens foram redimensionadas para 224 x 224 pixels, seguindo o padrão aceito pela YOLOv8m e nenhuma imagem foi removida independentemente do nível de ruído presente. Para todos os testes, os dados foram divididos em três conjuntos: treinamento (70%), teste (15%) e validação (15%). Cada espécie corresponde a uma classe, sendo variável para cada teste

performado. Em alguns casos em que há apenas o gênero ou família, esses também são considerados como uma classe.

2.4.2.2 Treinamento, validação, teste e análises de métricas

Devido às diferenças de quantidade de imagem por espécie, foi realizada *data augmentation* (aumento de dados) para assegurar o balanceamento de classes. Portanto, para que todas as classes tivessem a mesma quantidade de imagens foi utilizada uma *flag* (parâmetro) no momento de treinamento da rede que criou imagens a partir do banco de dados randomizando a transformação por meio das funções de rotação, *blur*, *crop* e *zoom*. A *data augmentation* é feita na matriz resultante de cada imagem, então as transformações são aplicadas nessas matrizes. Ou seja, uma parte das imagens é cortada, borrada, rotacionada e magnificada para aumentar o banco de dados ao mesmo tempo que simula variações de campo. Além disso, também foram usadas as funções *mosaic* e *mixup*.

Todas as redes foram inicialmente programadas para serem treinadas por 100 épocas e, durante cada época, os pesos da rede são ajustados para minimizar o erro entre as saídas previstas e as saídas reais. De acordo com a Ultralytics (2023), “cada época representa uma passagem completa por todo o conjunto de dados e o ajuste deste valor pode afetar a duração do treino e o desempenho do modelo”. Da mesma maneira, todos os testes iniciaram com *dropout* de 5%.

O *batch* é o tamanho de lote para treino e indica quantas imagens são processadas antes dos parâmetros internos serem automaticamente atualizados. O valor padrão para YOLOv8 é de 16 e foi utilizado para todos os testes deste estudo, assim como o otimizador *Stochastic Gradient Descent* (SGD). A otimização é realizada no processamento como um todo e a primeira a ser otimizada é a taxa de aprendizagem, que, por sua vez, modifica todo o conjunto do processamento em sequência. Para o algoritmo AdamW (*PyTorch*, 2023) os seguintes parâmetros foram estabelecidos (Quadro 4):

QUADRO 4 – PARÂMETROS DETERMINADOS PARA ADAMW

lr	0.000714
momentum	0.9
38 weight decay	0.0
39 weight decay	0.0005
39 bias decay	0.0
Image size train	224
Image size val	224

FONTE: A autora (2024).

A normalização foi feita por meio de uma multiplicação pré-determinada pelo modelo, em que:

$$y = \frac{x - a}{b - a}$$

Considerando-se uma matriz:

$$\begin{vmatrix} x & y & 1 \\ a & 0 & 1 \\ b & 1 & 1 \end{vmatrix}$$

Em que a: mínimo e b:máximo.

A taxa de aprendizagem (*learning rate*, lr) é modificada durante todo o processamento, sendo, portanto, variável. Contudo, a taxa de aprendizagem inicial (lr0) é igual a taxa de aprendizagem final (lrf) e possui valor de 0,1.

Em YOLOv8, a etapa de validação ocorre concomitantemente com a etapa de treinamento, e nela utilizou-se validação cruzada (especificamente, *k-fold cross-validation*), com k=10. Mesmo ocorrendo de forma concomitante, as imagens utilizadas para validação são diferentes daquelas utilizadas para o treinamento. Esta etapa é crucial para entender como o modelo performaria em dados reais e não vistos anteriormente. As métricas utilizadas para avaliação na fase de validação foram consistentes com as utilizadas durante o treinamento.

Usando o banco de dados combinado (combinação de todos os bancos de dados com cada classe contendo no mínimo 50 imagens), foram testados a influência do *mixup* e *mosaic*, assim como o uso de imagens coloridas versus imagens em escala de cinza.

Para avaliar o desempenho do modelo, foram analisadas as métricas: acurácia (apresentada tanto como matriz de confusão normalizada e acurácia

total do modelo), precisão, *recall* e *F1-score*, calculadas de acordo com as equações a seguir.

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

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

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

$$\text{F1-score} = 2 * \frac{\text{Precisão} * \text{Recall}}{\text{Precisão} + \text{Recall}}$$

Em que: VP: Verdadeiro Positivo;

VN: Verdadeiro Negativo

FP: Falso Positivo

FN: Falso Negativo

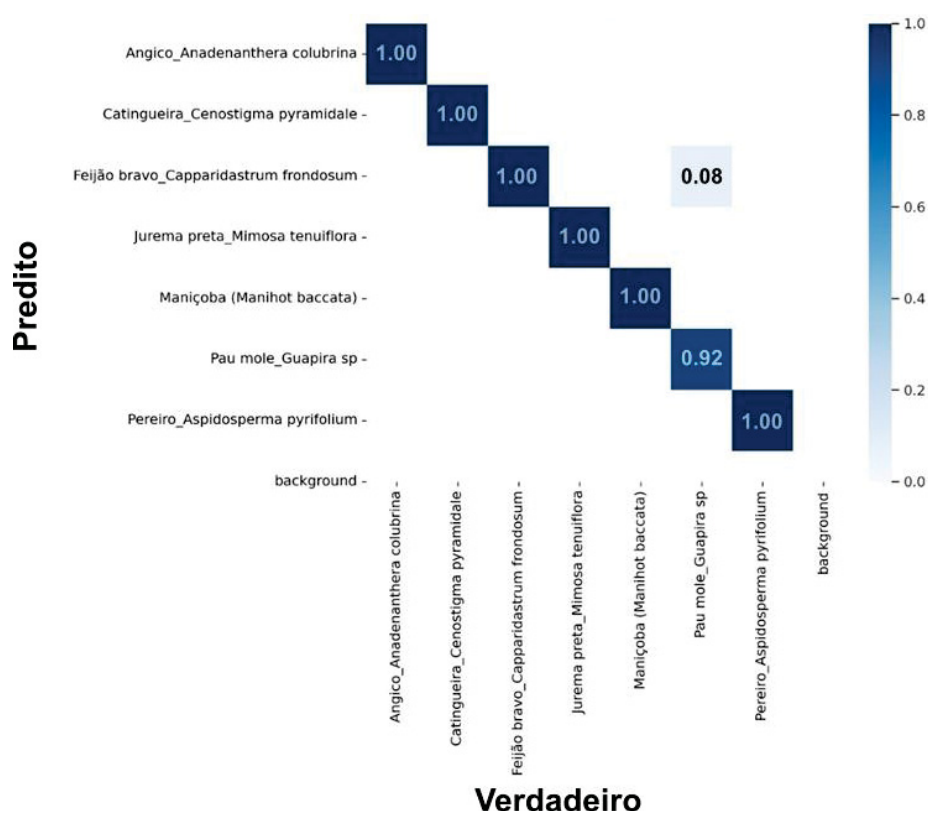
2.5 RESULTADOS E DISCUSSÃO

2.5.1 TESTE 1- BANCO DE DADOS CAATINGA

A maioria das imagens possuíam qualidade suficiente para a avaliação anatômica, contudo, algumas imagens apresentaram desfoques, diferença na iluminação, manchas, diferentes orientações, rachaduras e irregularidades derivadas do processo de polimento. Apesar disso, em sua maioria, ainda é possível verificar os caracteres anatômicos mais relevantes para sua identificação, sendo assim mantidas no banco de dados em conjunto com as imagens de maior qualidade.

O percentual de acerto do modelo na etapa de treinamento foi de 99,83%, com menor valor para *Guapira* sp. (Figura 16), a única espécie que obteve acurácia abaixo de 100%. A acurácia é a métrica que computa a quantidade de vezes em que um modelo fez uma predição correta em todo o banco de dados analisado. Devido ao processo de *data augmentation* aplicado no pré-processamento para o balanceamento de classes, essa métrica é confiável para a análise deste modelo. Dentre os trabalhos relatados no capítulo anterior, apenas o estudo de Yusof, Khalid e Khairuddin (2013), alcançou valor de acurácia superior (100%) com um banco de 5.200 imagens, melhoradas para *feature extraction* e obtidas de amostras que foram lixadas usando três gramaturas (400, 800 e 1000). Isto demonstra a sensibilidade da técnica ao alcançar valores altos de acurácia com imagens não tratadas, amostras com superfícies menos homogêneas e banco de dados menor.

FIGURA 16 – MATRIZ DE CONFUSÃO NORMALIZADA DO TESTE 1



Fonte: A autora (2024).

Em relação ao processo de validação, *Guapira* sp. teve o menor valor para precisão, enquanto as demais espécies atingiram o valor máximo de precisão (Tabela 7). Quanto ao *recall*, o menor valor foi referente a *Capparidastrum frondosum* (0,9878), enquanto as demais atingiram o valor máximo para este parâmetro. Por último, *Guapira* sp. apresentou menor valor para *F-1 score* (0,96), enquanto *Capparidastrum frondosum* foi o segundo menor (0,9939), com as demais classes atingindo o valor máximo. Por fim, mesmo os valores mais baixos ainda estão acima de 0,9, indicando que YOLOv8m apresenta grande potencial para classificação de espécies florestais a partir de imagens de madeira.

TABELA 7 – MÉTRICAS DA ETAPA DE VALIDAÇÃO DO TESTE 1

Espécie/Métrica	Precisão	Recall	F1-score
<i>Anadenathera colubrina</i>	1,00	1,00	1,00
<i>Aspidosperma pyriformium</i>	1,00	1,00	1,00
<i>Capparidastrium frondosum</i>	1,00	0,99	0,99
<i>Cenostigma pyramidale</i>	1,00	1,00	1,00
<i>Guapira</i> sp.	0,92	1,00	0,96
<i>Manihot baccata</i>	1,00	1,00	1,00
<i>Mimosa tenuiflora</i>	1,00	1,00	1,00

Fonte: A autora (2024).

A precisão, como o nome indica é a métrica que indica quão preciso é o modelo analisado e mede quantas predições positivas foram corretamente feitas (verdadeiro positivo). É demonstrada pela relação entre o número de instâncias corretamente preditas como positivas e o número total de instâncias positivas (verdadeiros positivos e falsos positivos). No caso deste estudo, é relação entre o número de imagens corretamente classificadas e o número de imagens atribuídas para determinada classe (previsões positivas feitas pelo modelo). Como o menor valor está acima de 0,9, o modelo apresenta alta precisão.


Recall se refere ao número de imagens corretamente identificadas pelo modelo dividido pelo número total de imagens que pertencem à referida classe. Ou seja, de todas as imagens que poderia classificar para determinada classe, quantas o modelo acertou. A importância desta métrica é que quanto maior é seu valor, maior será a redução do número de falsos negativos (instância em que uma instância positiva é incorretamente classificada como negativa). Neste estudo, o valor de *recall* está muito próximo do máximo, indicando que o número de imagens incorretamente classificados é baixo.

F1-score analisa a capacidade preditiva de um modelo por meio da performance de cada classe, ao contrário da acurácia, que analisa a performance geral do modelo. Esta métrica é a média harmônica de outras duas métricas (precisão e *recall*) e, portanto, indica se o modelo está equilibrando ou não essas métricas. Como os valores de F1-score do modelo testado estão próximos do valor máximo, as métricas estão equilibradas, portanto, o modelo

em si está equilibrado quanto à detecção das identificações positivas (*recall*) e acertos (precisão).

No treinamento, apenas uma imagem foi identificada de maneira incorreta (Figura 17), representando 0,17% do conjunto analisado, pertencendo à espécie *Guapira* sp. e predita como *Capparidastrum frondosum*. A anatomia dessas duas espécies não é semelhante, sendo *Guapira* sp. a espécie mais distinta entre as que compõem este banco de dados em razão da presença de ilhas de floema incluso. Contudo, os padrões presentes em ambas as espécies podem ser considerados como semelhantes, apresentando “faixas descontínuas” de branco (parênquima no caso de *Capparidastrum frondosum* e floema incluso no caso de *Guapira* sp.), faixas em tom semelhantes de cinza e bege, com dimensões relativamente próximas o suficiente para serem “lidas” como um conjunto de padrões semelhantes pelo algoritmo. Além disso, a imagem em questão apresentou um certo nível de ruído (manchas, desfoque, diferença de iluminação), portanto, é possível que essas imperfeições também tenham influenciado no decréscimo da acurácia.

FIGURA 17 – IMAGEM IDENTIFICADA INCORRETAMENTE E ESPÉCIE COM A QUAL FOI CONFUNDIDA



FONTE: A autora (2024).

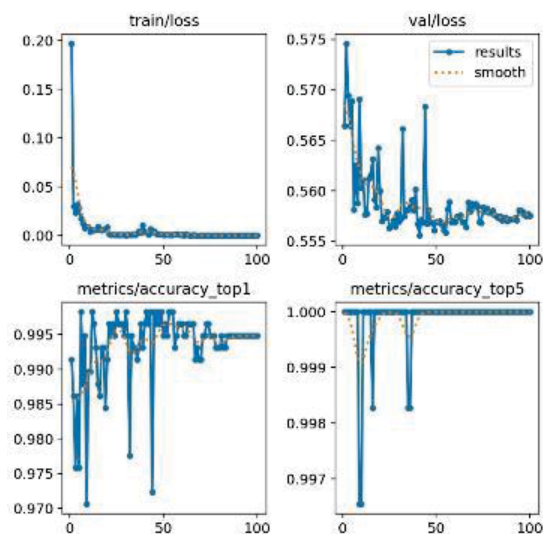
LEGENDA: (A): imagem de *Guapira* sp. erroneamente identificada como *Capparidastrum frondosum* (B): imagem de *Capparidastrum frondosum*.

O descarte de imagens de menor qualidade (ruídos significativos) poderia aumentar ainda mais a acurácia, contudo, isso seria uma superestimação desta métrica e não refletiria os aspectos práticos correlatos à aquisição de uma imagem obtida em condições de campo, e a partir de material não previamente

polido, por exemplo. Portanto, a robustez do modelo testado neste estudo é mais uma vez destacada por apresentar excelentes métricas, mesmo com algumas imagens com ruídos significativos devido às irregularidades de diversas naturezas das amostras (ataque de biodeterioradores, inchamento e contração das amostras), além de diferenças no acabamento da superfície.

Em redes neurais, o valor de *loss* representa a diferença entre o valor de saída da rede e o esperado para uma determinada entrada. Por sua vez, a diminuição gradativa do valor de *loss* a cada época indica que a rede está obtendo mais sucessos ao fazer previsões. Inicialmente, determinou-se que o teste seria com 100 épocas e *dropout* de 5% e o resultado foi um modelo com 100% de acurácia, contudo, devido ao ponto de convergência estar muito próximo de 100 épocas para *validation x loss*, acredita-se que havia um risco de ter acontecido um sobreajuste (*overfitting*). Ou seja, ao invés do modelo estar aprendendo, ele estava na verdade decorando, sendo, portanto, não aplicável. Para eliminar essa possibilidade, aumentou-se o número de épocas para 300 e *dropout* para 10% e processou-se novamente o modelo. Desta vez, o processamento parou automaticamente de forma antecipada em 100 épocas (Figura 18), ou seja, atingiu o valor de *patience*, indicando que não gerou melhores resultados nas próximas épocas. O processamento deste teste durou 3 horas, 48 minutos e 15 segundos.

FIGURA 18 – GRÁFICOS DE PERDAS VERSUS TREINAMENTO, PERDAS VERSUS VALIDAÇÃO E ACURÁCIA TOP1 E TOP 5 – TESTE 1



FONTE: A autora (2024).

No início do treinamento o valor de perdas é maior e reduz gradativamente ao decorrer do processamento, enquanto há aumento da acurácia (Figura 18). Durante o treinamento há um ponto em que não há mais diminuição de perdas nem aumento da acurácia e é neste ponto que o treinamento deve ser parado para reduzir custos operacionais já que o modelo não apresentará mais melhorias. *Patience* é o valor de épocas que o modelo continua processando após atingir o ponto em que não há mais melhorias quanto às perdas e acurácia, sendo essa parada antecipada ou forçada, o que auxilia a determinar o melhor ponto de equilíbrio entre a performance do modelo e tempo de processamento e utilização de recursos computacionais. Além disso, um número muito grande de épocas apresenta maior risco de sobreajuste, enquanto um número muito pequeno pode resultar em um modelo não adequado. Portanto, o *patience* funciona como um indicador, como uma “trava” ou “margem de segurança” ao parar o processamento em um ponto ótimo. A determinação do valor de *patience*, portanto é essencial para atingir esse equilíbrio. Se seu valor for muito baixo, ele resultará em uma parada prematura do processamento, potencialmente deixando de atingir o ponto ótimo entre perdas e acurácia. Já se o valor de *patience* for muito alto, o treinamento poderá ser prolongando de maneira desnecessária, resultando no desperdício de recursos.

No modelo avaliado, mesmo aumentando o número de épocas (de 100 para 300), o valor de *patience* foi atingindo próximo a 100 épocas, indicando que o ponto ótimo de épocas do modelo é próximo de 100 e o sobreajuste foi efetivamente evitado pelo aumento do valor de *dropout* (de 5% para 10%).

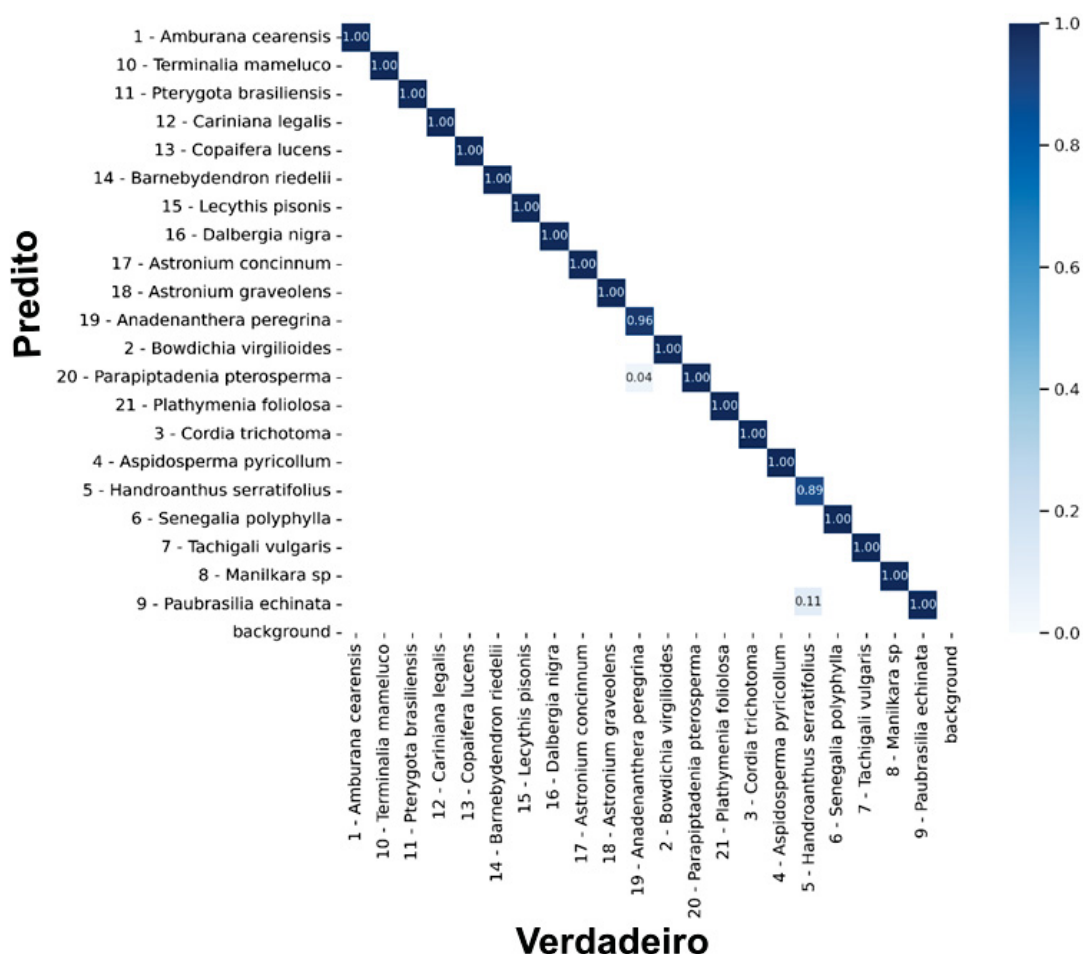
2.5.2 TESTE 2 - BANCO DE DADOS MATA ATLÂNTICA

Neste segundo teste, a acurácia foi de 99,51%. De acordo com a matriz de confusão (Figura 19), apenas *Handroanthus serratifolius* e *Anadenanthera peregrina* tiveram amostras que foram erroneamente identificadas durante a etapa de teste (Figura 20), com todas as outras imagens das 19 espécies sendo identificadas corretamente. Um total de três imagens foram identificadas incorretamente, sendo duas de *Handroanthus serratifolius* e uma de *Anadenanthera peregrina*, enquanto no estudo de Andrade, Basso e Latorraca (2020), apenas duas espécies foram corretamente identificadas completamente,

com todas as outras apresentando de uma até três imagens erroneamente identificadas por espécie, e o melhor teste apresentou uma acurácia de 97,7%.

Esses autores justificam o percentual de erros com a qualidade da superfície de algumas amostras e a baixa qualidade de algumas imagens, sendo válido destacar que os autores utilizaram a função *adapthisteq* do *software* Matlab R2018a (*Image Processing and Statistics e Machine Learning toolboxes*) para o pré-processamento das imagens, equalizando seus histogramas, melhorando o contraste e minimizando os efeitos de iluminação não homogênea, enquanto no presente estudo nenhum tipo de processamento foi aplicado para a melhoria da qualidade da imagem, economizando assim recursos computacionais e tempo.

FIGURA 19 – MATRIZ DE CONFUSÃO NORMALIZADA DO TESTE 2




FONTE: A autora (2024).

Andrade, Basso e Latorraca (2020) testaram 4 resoluções, diferentes configurações de matrizes de GLCM, dois tipos de características (matriz de co-ocorrência - CM, e matriz de co-ocorrência pura - *raw* CM) e diferentes quantidades de características de interesse extraídas (18, 382, 399, 404, 407 e 350). O percentual de erros na etapa de treinamento encontrada por esses autores variou de 2,35% a 8,50%, com o menor erro associado a imagens de resolução 306 x 408 pixels, valores de erro muito superiores ao encontrado no presente trabalho (0,73%) utilizando imagens com 224 x 224 pixels. Além da quantidade de informações disponíveis, o tamanho da imagem também tem relação diretamente proporcional com o tempo de processamento, já que quanto maior a quantidade de informações a ser analisada, maior é o tempo necessário para fazê-lo.

No presente estudo, as duas imagens de *H. serratifolius* (Figura 20 A-B) foram identificadas como *Paubrasilia echinata*, algo provavelmente explicado pela semelhança do conjunto de seus caracteres anatômicos (porosidade difusa, poros em sua maioria solitários, de dimensões semelhantes, com parênquima axial paratraqueal aliforme losangular com curtas porções confluentes) e raios finos. O mesmo pressuposto pode ser inferido para a incorreta identificação da imagem de *Anadenanthera peregrina* como *Parapiptadenia pterosperma*: ambas apresentam parênquima axial paratraqueal vasicêntrico, poros de diâmetros semelhantes (com *A. peregrina* aparentando ser ligeiramente maiores), em sua maioria solitários, múltiplos radiais pouco frequentes e raios finos; até mesmo a coloração da madeira é bem próxima em parte das imagens.

FIGURA 20 – IMAGENS IDENTIFICADAS INCORRETAMENTE NO TESTE 2



FONTE: A autora (2023).

LEGENDA: A-C: espécies verdadeiras; D-F: espécies preditas. A-B: *Handroanthus serratifolius*; C: *Anadenanthera peregrina*; D-E: *Paubrasilia echinata*; F: *Parapiptadenia pterosperma*.

Portanto, os poucos erros cometidos provavelmente se originam da semelhança anatômica das espécies, sendo interpretados como detentores de padrões (texturas) semelhantes e, portanto, como de maior compatibilidade/probabilidade matemática às imagens rotuladas durante o treinamento como a espécie que foi erroneamente identificada. Ou seja, é provável que os valores atribuídos a suas características foram interpretados como iguais ou semelhantes o suficiente, de acordo com as métricas e intervalos de parâmetros predeterminados pela arquitetura, para serem atribuídos determinado rótulo.

De acordo com o reportado por Andrade, Basso e Latorraca (2020), o menor percentual de erro alcançado em seu trabalho na etapa de teste foi de 2,35%, enquanto o alcançado no presente trabalho foi de 0,73%. O percentual de erro alcançado no presente teste é bem menor do que relatado em 81,8% dos trabalhos listados no capítulo anterior, apresentando-se como extremamente

próximo a uma acurácia perfeita, algo muitas vezes não alcançado por um *expert* em anatomia.

Outra ponto que deve ser considerado para esta discussão é o tamanho do banco de dados dos trabalhos que alcançaram igual ou maior percentual de acurácia do que o alcançado neste teste (banco com 2002 imagens): a acurácia reportada por He et al. (2020) foi de 99,3% a partir de um banco de 10.237 imagens; o mesmo percentual foi alcançado por Kwon et al. (2017) usando um banco de dados de 16.865 imagens; Sun et al. (2021) alcançaram acurácia de 99,6% com 3000 imagens; e Yusof, Khalid e Khairuddin (2013), que alcançaram a marca de 100% de acurácia com um banco de 5.200 imagens.

Em uma interpretação/abordagem estatística, é sabido que um maior banco de dados está diretamente relacionado com a confiabilidade do modelo e fidelidade dos resultados teóricos alcançados frente às situações práticas e reais e sua consequente aplicabilidade. Contudo, contrapõem-se a isso os recursos necessários para alcançar tal robustez, sua aplicação em situações rotineiras, não só laboratoriais, mas principalmente de fiscalização, *versus* os recursos necessários para sua aquisição e processamento (tempo de aquisição e processamento das imagens e *hardware* necessário pra isto).

Além da quantidade de imagens, outra diferença se refere ao preparo da superfície: neste estudo, o preparo se deu apenas com um pouco de água e corte com faca, enquanto os trabalhos que tiveram acurácia próxima ou mais alta do que o presente estudo, usaram diversas e altas gramaturas. Yusof, Khalid e Khairuddin (2013) e Sun et al. (2021) utilizaram três gramaturas (400, 800 e 1000) enquanto He et al. (2020) preparou seu material com um total de seis gramaturas (80, 240, 400, 800, 1000, 1500), resultando em um acabamento mais detalhado e homogêneo, porém muito diferente das superfícies que geralmente são utilizadas para a identificação em campo, não sendo praticável nessas situações. Por último, o trabalho de Yusof, Khalid e Khairuddin (2013), que atingiu acurácia perfeita, utilizou de artifícios para melhorar a seleção de características na etapa de *feature extraction*.

Exceto para *Paubrasilia echinata* e *Parapiptadenia pterosperma*, a precisão e o F1-score para todas as classes atingiram o valor máximo (Tabela 8). Para recall, os menores valores foram para *Handroanthus serratifolius* e *Anadenanthera peregrina*. Para as três métricas, os menores valores ficaram

acima de 0,86, indicando que o modelo além de apresentar alta acurácia, também tem alta precisão, sensibilidade e boa capacidade preditiva.

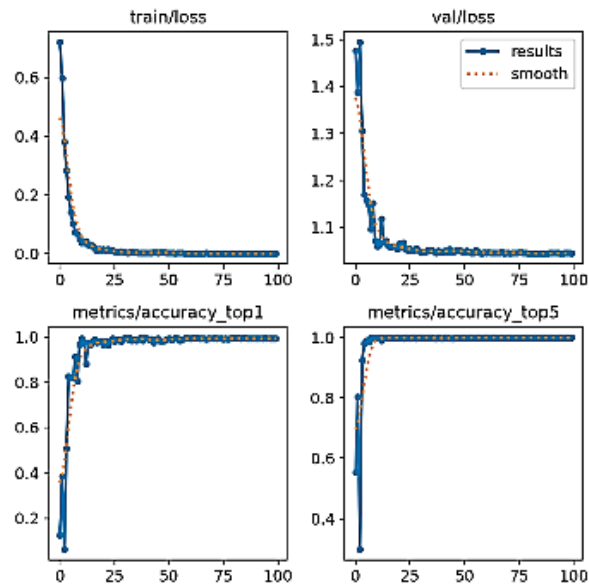
TABELA 8 – MÉTRICAS DA ETAPA DE VALIDAÇÃO DO TESTE 2

Espécie/Métrica	Precisão	Recall	F1-score
<i>Astronium concinnum</i>	1,00	1,00	1,00
<i>Astronium graveolens</i>	1,00	1,00	1,00
<i>Aspidosperma pyricollum</i>	1,00	1,00	1,00
<i>Handroanthus serratifolius</i>	1,00	0,87	0,93
<i>Cordia trichotoma</i>	1,00	1,00	1,00
<i>Terminalia mameluco</i>	1,00	1,00	1,00
<i>Amburana cearensis</i>	1,00	1,00	1,00
<i>Bowdichia virgilioides</i>	1,00	1,00	1,00
<i>Senegalia polyphylla</i>	1,00	1,00	1,00
<i>Tachigali vulgaris</i>	1,00	1,00	1,00
<i>Paubrasilia echinata</i>	0,89	1,00	0,94
<i>Copaifera lucens</i>	1,00	1,00	1,00
<i>Barnebydendron riedelii</i>	1,00	1,00	1,00
<i>Dalbergia nigra</i>	1,00	1,00	1,00
<i>Anadenanthera</i>	1,00	0,95	0,98
<i>Parapiptadenia pterosperma</i>	0,96	1,00	0,98
<i>Plathymenia foliolosa (Plathymenia reticulata)</i>	1,00	1,00	1,00
<i>Cariniana legalis</i>	1,00	1,00	1,00
<i>Lecythis pisonis</i>	1,00	1,00	1,00
<i>Pterygota brasiliensis</i>	1,00	1,00	1,00
<i>Manilkara sp.</i>	1,00	1,00	1,00

Fonte: A autora (2024).

O *dropout* de 5% e 100 épocas foram suficientes para atingir bons resultados (Figura 21), e este modelo atingiu o valor de *patience* na época 87. Ao longo do treinamento a rede adapta os pesos cada vez mais devagar, convergindo para uma solução. O intervalo de 100 épocas foi definido com uma “margem de segurança” após o ponto de convergência, garantindo que a rede aprendesse características principais de cada espécie sem o risco de *overfitting* (superajuste) ao conjunto de treinamento. Este teste teve duração total de 3 horas, 42 minutos e 49 segundos

FIGURA 21 – GRÁFICOS DE PERDAS VERSUS TREINAMENTO, PERDAS VERSUS VALIDAÇÃO E ACURÁCIA TOP1 E TOP 5 DO TESTE 2



FONTE: A autora (2024).

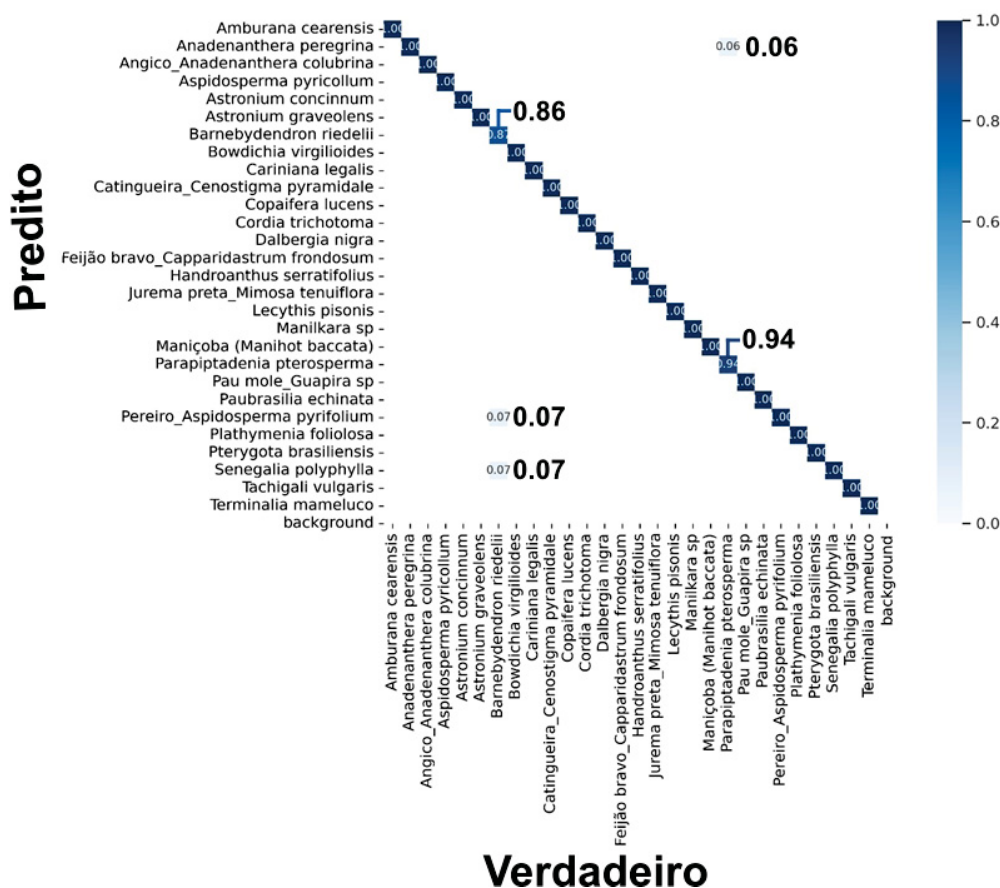
Mesmo com imagens com ruídos (marcas irregulares produzidas pela lâmina de corte, iluminação heterogênea, irregularidades na superfície da amostra devido ao polimento, e resistência da madeira ao corte, além de desfoque), o YOLOv8m teve sensibilidade suficiente para conseguir extrair os caracteres de interesse a ponto de se igualar ou se aproximar de trabalhos com alta acurácia a partir de superfícies previamente polidas e virtualmente sem ruídos. Portanto, o presente estudo, mais uma vez se destaca pela menor utilização de recursos, já que o tempo de preparo da amostra é menor (menor quantidade de gramaturas), menor quantidade de imagens (menor tempo de aquisição do banco e processamento, menor uso de recursos computacionais) ao mesmo tempo que possui alto valor de acurácia.

Por último, é válido salientar que YOLOv8m apresentou sensibilidade suficiente pra distinguir espécies muito semelhantes, sendo um atributo de grande relevância para o mercado madeireiro, especialmente no que tange à fiscalização.

2.5.3 TESTE 3 - BANCO DE DADOS CAATINGA + MATA ATLÂNTICA

Este teste resultou em acurácia de 99,58%, apresentando duas classes com problemas de identificação, *Barnebydendron riedelii* e *Parapiptadenia pterosperma*, dentre um total de 28 espécies (Figura 22). Destaca-se o fato que esta acurácia foi alcançada a partir de um banco de dados com imagens obtidas em diferentes condições de iluminação, diferentes magnificações, equipamento distintos (mesmo que ambos tenham sido de celulares), diferentes preparos de superfície e diferentes resoluções originais e mesmo assim o uso de YOLOv8m se mostrou eficiente na distinção e identificação de espécies de madeira. Sun et al. (2021) alcançaram acurácia de 99,6% com imagens obtidas de amostras que foram lixadas com gramaturas mais finas e, portanto, mais homogêneas, o mesmo é válido para o trabalho de Yusof, Khalid e Khairuddin (2013), que alcançaram a marca de 100% de acurácia com artifícios para melhorar a seleção de características na etapa de *feature extraction*.


FIGURA 22 – MATRIZ DE CONFUSÃO NORMALIZADA DO TESTE 3



FONTE: A autora (2024).

Na Figura 23 há a comparação entre as espécies verdadeiras (A-C) e as respectivas espécies erroneamente preditas (D-F). *Barnebydendron riedelii* (Figura 23 A-B) foi erroneamente identificada como *Aspidosperma pyriformium* (Figura 23 D) e *Senegalia polyphylla* (Figura 23 E), enquanto *Parapiptadenia pterosperma* (Figura 23 C) foi incorretamente identificada como *Anadenanthera peregrina* (Figura 23 E), sendo este último duo também confundido no teste anterior, porém na ordem inversa. Exceto para o par A/D, os demais pares foram confundidos em razão de semelhanças anatômicas, como parênquima aliforme losangular tendendo a linhas irregulares (porém com espessuras distintas), vasos majoritariamente solitários e raios com dimensões aparentemente próximas para o par B/E. Para o par C/F os vasos são solitários e de dimensões semelhantes, o parênquima é vasicêntrico para a maioria dos vasos em ambas as espécies, com aliformes losangulares raros. Em ambos os pares, de maneira geral, a organização dos caracteres apresenta padrão semelhante, o que originou a confusão pelo modelo. O par A/D não possui nenhuma semelhança anatômica ou de padrões e nem pertencem à mesma família botânica, portanto, a confusão entre essas duas imagens pode derivar de algum erro durante o processamento que será investigado em trabalhos futuros de refinamento da técnica.

FIGURA 23 – IMAGENS IDENTIFICADAS INCORRETAMENTE NO TESTE 3



FONTE: A autora (2024).

LEGENDA: Verdadeiras (A-C) e preditas (D-F). A e B: *Barnebydendron riedelii*; C: *Parapiptadenia pterosperma*; D: *Aspidosperma pyrifolium*; E: *Senegalia polyphylla*; F: *Anadenanthera peregrina*.

A confusão na identificação de madeiras entre indivíduos de diferentes gêneros e/ou famílias que apresentam características anatômicas semelhantes é algo extensivamente relatado, tanto na literatura especializada como em situações comerciais e de fiscalização, gerando prejuízos de cunho econômico e ecológico. Além disto, há uma certa probabilidade de erro associada a indivíduos de mesmo nível taxonômico, especialmente de mesmo gênero, já que compartilham características semelhantes, portanto, sendo esperado que as chances de confusão nesses grupos sejam maiores. Neste teste há gêneros que apresentam mais de uma espécie que não foram confundidas entre si (duas espécies do gênero *Anadenanthera*, duas espécies do gênero *Aspidosperma* e duas espécies do gênero *Astronium*), além de 14 espécies da família Fabaceae e duas espécies da família Lecythidaceae, em que todas as imagens foram corretamente identificadas neste teste, demonstrando mais uma vez o potencial preditivo de YOLOv8m.

Barnebydendron riedelii foi a espécie com os piores valores para precisão e F1-score (Tabela 9), enquanto *Anadenanthera peregrina* e *Senegalia polyphylla* apresentaram o pior valor para *recall*. Contudo, todos os valores foram acima de 0,85, indicando que o modelo é preciso, sensível e com bom poder preditivo.

Neste teste, o *dropout* foi de 10% e atingiu o valor de *patience* na época 87, mas é possível observar queda na acurácia após a época 75 (Figura 24). Por mais que ainda apresente o mesmo comportamento de iniciar o teste com *loss* alta e finalizar com *loss* baixa, é possível observar que os gráficos de *loss* para treinamento e validação não são tão homogêneos, com o gráfico de *loss* de validação apresentando oscilações significativas entre épocas, o que contrasta com os testes anteriores. Essas oscilações possivelmente podem ser atribuídas a uma característica detectada pela rede que não gera uma boa divisibilidade, podendo ser semelhança interclasses ou variação intraclasses. Isso também é refletido na acurácia, contudo a acurácia top 1 (que se refere à classe que possui maior probabilidade de ser compatível com a imagem avaliada) apresentou menor amplitude de oscilação em comparação à acurácia top 5. O processamento deste teste durou 3 horas, 32 minutos e 56 segundos.

TABELA 9 – MÉTRICAS RESULTANTES DO MODELO PERFORMADO NO TESTE 3 (CONTINUA)

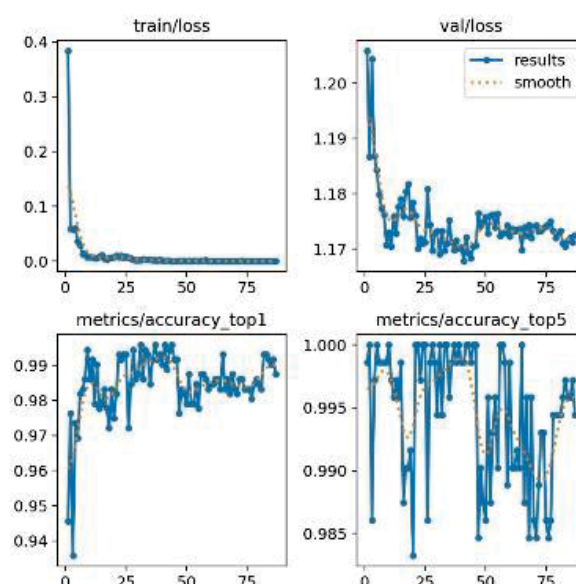
Espécie	Precisão	Recall	F1-score
<i>Guapira</i> sp.	1,00	1,00	1,00
<i>Manilkara</i> sp.	1,00	1,00	1,00
<i>Tachigali vulgaris</i>	1,00	1,00	1,00
<i>Anadenanthera peregrina</i>	1,00	0,94	0,97
<i>Cenostigma pyramidale</i>	1,00	1,00	1,00
<i>Copaifera lucens</i>	1,00	1,00	1,00
<i>Plathymania foliolosa</i>	1,00	1,00	1,00
<i>Handroanthus serratifolius</i>	1,00	1,00	1,00
<i>Lecythis pisonis</i>	1,00	1,00	1,00
<i>Aspidosperma pyriformium</i>	1,00	0,98	0,99
<i>Pterygota brasiliensis</i>	1,00	1,00	1,00
<i>Manihot baccata</i>	1,00	1,00	1,00
<i>Cordia trichotoma</i>	1,00	1,00	1,00
<i>Bowdichia virgilioides</i>	1,00	1,00	1,00
<i>Barnebydendron riedelii</i>	0,87	1,00	0,93
<i>Paubrasilia echinata</i>	1,00	1,00	1,00
<i>Capparidastrum frondosum</i>	1,00	1,00	1,00
<i>Cariniana legalis</i>	1,00	1,00	1,00

TABELA 9 – MÉTRICAS RESULTANTES DO MODELO PERFORMADO NO TESTE 3 (FINAL)

Espécie	Precisão	Recall	F1-score
<i>Astronium concinnum</i>	1,00	1,00	1,00
<i>Astronium graveolens</i>	1,00	1,00	1,00
<i>Parapiptadenia pterosperma</i>	0,94	1,00	0,97
<i>Dalbergia nigra</i>	1,00	1,00	1,00
<i>Aspidosperma pyricollum</i>	1,00	1,00	1,00
<i>Mimosa tenuiflora</i>	1,00	1,00	1,00
<i>Senegalia polyphylla</i>	1,00	0,94	0,97
<i>Terminalia mameluco</i>	1,00	1,00	1,00
<i>Amburana cearensis</i>	1,00	1,00	1,00
<i>Anadenanthera colubrina</i>	1,00	1,00	1,00

Fonte: A autora (2024).

FIGURA 24 – GRÁFICOS DE PERDAS VERSUS TREINAMENTO, PERDAS VERSUS VALIDAÇÃO E ACURÁCIA TOP1 E TOP 5 DO TESTE 3



FONTE: A autora (2024).

2.5.4 TESTE 4 BANCO DE DADOS CAATINGA + MATA ATLÂNTICA + FSD-M + EFS+PF

Neste último foram utilizadas imagens de cinco banco de dados distintos abrangendo 59 espécies, além de 12 classes identificadas apenas a nível de gênero, totalizando 71 classes distribuídas em 25 famílias, em sua maioria nativas da Mata Atlântica, Amazônia e Caatinga, mas com algumas classes de exóticas com importância comercial. A família com o maior número de classes é

Fabaceae (23), seguida por Apocynaceae e Lecythidaceae (5 cada uma), e Meliaceae e Sapotaceae (4). Neste banco, 9 gêneros têm duas ou mais espécies, sendo *Aspidosperma* o gênero com maior número de espécies (4).


❖ Parte 1: sem *mixup* e *mosaic*, imagens coloridas

Neste processamento, que perdurou 11 horas e 05 minutos, a acurácia foi de 99,455% com 9 erros de identificação de 9 espécies distintas, contudo, a rede decorou e não aprendeu, invalidando o modelo.

❖ Parte 2: com *mixup* e *mosaic*, imagens coloridas

Este processamento foi realizado em 4 horas, 52 minutos e 46 segundos e teve como acurácia geral o valor de 99,64%, apresentando problema de identificação em 6 classes distintas (Figuras 25 e 26) das 71 incluídas no teste. No primeiro agrupamento (Figura 25), apesar de apresentarem algumas semelhanças em seus padrões, suas características anatômicas não parecem ser similares o suficiente para explicar a confusão, portanto, é mais provável que a confusão tenha se dado em razão de problemas durante a obtenção das imagens, já que as Figuras 25 A-C apresentam diferentes níveis de desfoque (mais elevados em 25B e 25C), além de problemas de resolução do equipamento de obtenção (B e C). Entre as Figuras 25C e 25F o preparo de superfície de *Cedrela fissilis* também pode ter influenciado o resultado. Analisando as imagens dos bancos de dados para *Cedrelinga cateniformis* e *Pinus* sp., o preparo da superfície pode ter influenciado a confusão, já que algumas imagens apresentam riscos e/ou pouca distinção dos caracteres anatômicos.

FIGURA 25 – IMAGENS IDENTIFICADAS INCORRETAMENTE NO TESTE 4 – GRUPO 1




FONTE: A autora (2024).

LEGENDA: Verdadeiras (A-C) e preditas (D-F). A: *Bertholletia excelsa*; B: *Cariniana estrellensis*; C: *Handroanthus* sp.; D: *Cedrelinga cateniformis*; E: *Pinus* sp.; F: *Cedrela fissilis*.

Por outro lado, para as imagens da Figura 26 A-C o fator preponderante para a confusão das espécies parece ser o preparo da superfície em ambas categorias (verdadeiras e preditas). Isto parece ser mais exacerbado nas Figuras 26B-C e 26E-F em que são notáveis marcas de lixa em todas as imagens e porções em que os caracteres não estão tão nítidos. Além disso, para estes pares, há semelhança nos contrastes entre as estruturas (parênquima e fibras e zonas de crescimento).

FIGURA 26 – IMAGENS IDENTIFICADAS INCORRETAMENTE NO TESTE 4 – GRUPO 2



FONTE: A autora (2024).

LEGENDA: Verdadeiras (A-C) e preditas (D-F). A: *Mimosa scabrella*; B: *Mimosa tenuiflora*; C: *Swietenia macrophylla*; D: *Carapa guianensis*; E: *Handroanthus* sp.; F: *Carapa guianensis*.

As métricas são apresentadas na Tabela 10.

TABELA 10 – MÉTRICAS DO TESTE 4, PARTE 2 (CONTINUA)

Espécie	Precisão	Recall	F1-score
<i>Acrocarpus fraxinifolius</i>	1,00	1,00	1,00
<i>Amburana cearensis</i>	1,00	1,00	1,00
<i>Anadenanthera colubrina</i>	1,00	1,00	1,00
<i>Anadenanthera peregrina</i>	1,00	1,00	1,00
<i>Apuleia leiocarpa</i>	1,00	1,00	1,00
<i>Araucaria angustifolia</i>	1,00	1,00	1,00
<i>Aspidosperma polyneuron</i>	1,00	1,00	1,00
<i>Aspidosperma pyricollum</i>	1,00	1,00	1,00
<i>Aspidosperma pyrifolium</i>	1,00	1,00	1,00
<i>Aspidosperma</i> sp.	1,00	1,00	1,00
<i>Astronium concinnum</i>	1,00	1,00	1,00
<i>Astronium graveolens</i>	1,00	1,00	1,00
<i>Bagassa guianensis</i>	1,00	1,00	1,00
<i>Balfourodendron riedelianum</i>	1,00	1,00	1,00
<i>Barnebydendron riedelii</i>	1,00	1,00	1,00
<i>Bertolletia excelsa</i>	0,95	1,00	0,97
<i>Bowdichia</i> sp.	1,00	1,00	1,00

TABELA 10 – MÉTRICAS DO TESTE 4, PARTE 2 (CONTINUA)

Espécie	Precisão	Recall	F1-score
<i>Bowdichia virgilioides</i>	1,00	1,00	1,00
<i>Brosimum paraensis</i>	1,00	1,00	1,00
<i>Capparidastrium frondosum</i>	1,00	1,00	1,00
<i>Carapa guianensis</i>	1,00	0,86	0,92
<i>Cariniana estrellensis</i>	0,94	1,00	0,97
<i>Cariniana legalis</i>	1,00	1,00	1,00
<i>Cedrela fissilis</i>	1,00	0,92	0,96
<i>Cedrelinga cateniformis</i>	1,00	0,98	0,99
<i>Cenostigma pyramidale</i>	1,00	1,00	1,00
<i>Clarisia racemosa</i>	1,00	1,00	1,00
<i>Copaifera lucens</i>	1,00	1,00	1,00
<i>Cordia alliodora</i>	1,00	1,00	1,00
<i>Cordia goeldiana</i>	1,00	1,00	1,00
<i>Cordia trichotoma</i>	1,00	1,00	1,00
<i>Couratari</i> sp.	1,00	1,00	1,00
<i>Dalbergia nigra</i>	1,00	1,00	1,00
<i>Dipteryx</i> sp.	1,00	1,00	1,00
<i>Erisma uncinatum</i>	1,00	1,00	1,00
<i>Eucalyptus</i> sp.	1,00	1,00	1,00
<i>Euxylophora paraensis</i>	1,00	1,00	1,00
<i>Goupia glabra</i>	1,00	1,00	1,00
<i>Grevilea robusta</i>	1,00	1,00	1,00
<i>Guapira</i> sp.	1,00	1,00	1,00
<i>Handroanthus serratifolius</i>	1,00	1,00	1,00
<i>Handroanthus</i> sp.	0,95	0,96	0,97
<i>Hymenaea</i> sp.	1,00	1,00	1,00
<i>Hymenolobium petraeum</i>	1,00	1,00	1,00
<i>Laurus nobilis</i>	1,00	1,00	1,00
<i>Lecythis pisonis</i>	1,00	1,00	1,00
<i>Machaerium</i> sp.	1,00	1,00	1,00
<i>Manihot baccata</i>	1,00	1,00	1,00
<i>Manilkara huberi</i>	1,00	1,00	1,00
<i>Manilkara</i> sp.	1,00	1,00	1,00
<i>Melia azedarach</i>	1,00	1,00	1,00

TABELA 10 – MÉTRICAS DO TESTE 4, PARTE 2 (FINAL)

Espécie	Precisão	Recall	F1-score
<i>Mezilaurus itauba</i>	1,00	1,00	1,00
<i>Micropholis venulosa</i>	1,00	1,00	1,00
<i>Mimosa scabrella</i>	0,93	1,00	0,96
<i>Mimosa tenuiflora</i>	0,99	1,00	0,99
<i>Myroxylon balsamum</i>	1,00	1,00	1,00
<i>Ocotea porosa</i>	1,00	1,00	1,00
<i>Parapiptadenia pterosperma</i>	1,00	1,00	1,00
<i>Paubrasilia echinata</i>	1,00	1,00	1,00
<i>Peltogyne</i> sp.	1,00	1,00	1,00
<i>Pinus</i> sp.	1,00	0,95	0,98
<i>Podocarpus lambertii</i>	1,00	1,00	1,00
<i>Pouteria pachycarpa</i>	1,00	1,00	1,00
<i>Pterygota brasiliensis</i>	1,00	1,00	1,00
<i>Senegalia polyphylla</i>	1,00	1,00	1,00
<i>Simarouba amara</i>	1,00	1,00	1,00
<i>Swietenia macrophylla</i>	0,97	1,00	0,99
<i>Tachigali vulgaris</i>	1,00	1,00	1,00
<i>Terminalia mameluco</i>	1,00	1,00	1,00
<i>Virola surinamensis</i>	1,00	1,00	1,00
<i>Vochysia</i> sp.	1,00	1,00	1,00

Fonte: A autora (2024).

Mimosa scabrella foi a classe que apresentou o menor valor de precisão, enquanto *Carapa guianensis* foi a classe com menores valores para *recall* e F-1 score.

Ao comparar o uso de *mixup* e *mosaic*, além da redução de recursos (especialmente computacionais, já que o tempo de processamento do teste sem *mixup* e *mosaic* foi de cerca de 11 horas em contraste com as quase 5 horas para o processamento integrando *mixup* e *mosaic*, reduzindo o tempo de processamento pela metade), a inclusão desses dois recursos também preveniu o *overfitting* do modelo, garantindo o processo de aprendizagem sem perder acurácia.

❖ Parte 3: com *mixup* e *mosaic*, imagens em escala de cinza

As mesmas classes e quantidades de imagens usadas nas duas partes anteriores foram utilizadas para a terceira parte do Teste 4, exceto que ao invés de usar as imagens coloridas as imagens foram convertidas pra escala de cinza antes de seu processamento.


A vasta maioria dos trabalhos que se baseiam em imagens para a identificação de madeiras tem como uma das primeiras etapas o pré-processamento das imagens convertendo-as de coloridas para escala de cinza, eliminando a cor como uma fonte de variação e possível determinante para a confusão de espécimes (anatomicamente) distintos. Esta preocupação é válida e fundamentada no fato de que, além de existir um número elevado de espécies distintas que apresentam coloração muito semelhante, há o fato de que uma mesma espécie pode apresentar uma certa variação de coloração relacionada às características de sítio, genética, idade, além de variação dentro de uma mesma árvore em relação à altura e à posição medula-casca (madeira juvenil x madeira adulta) (Dzurenda, 2023; Moya, Calvo-Alvarado, 2012; Phelps et al., 1983; Sotelo Montes et al., 2013; Traoré et al., 2023). Ademais, após a derrubada da árvore, a madeira também sofrerá modificação em sua coloração em razão de exposição ao elementos (intemperismo) e processos de oxidação intrínsecos ao envelhecimento do material (Arpaci et al., 2021; Gurău et al., 2023; Kropat et al., 2020; Matsuo et al., 2011; Rütther, Jelle, 2011). Como o esforço amostral para representar toda essa variedade é impraticável a curto prazo, os estudos geralmente eliminam essa variável ao transformar a imagem em escala de cinza. Assim, os contrastes entre os elementos anatômicos são preservados (às vezes até acentuados), assim como suas formas e texturas, mantendo o “padrão anatômico” ainda reconhecível para o devido processamento.

Portanto, para compreender a sensibilidade do modo de classificação do YOLOv8 em relação à cor, as mesmas imagens deste banco de dados foram transformadas de coloridas para escala de cinza. O processamento total contabilizou 3 horas 46 minutos e 27 segundos, atingiu acurácia de 99,2% e contabilizou 6 espécies erroneamente identificadas, totalizando 7 imagens (Figuras 27 e 28).

Na Figura 27, o primeiro par de espécies (*Balfourodendron riedelianum* x *Cariniana estrellensis*) apresenta raios finos, mais ou menos regularmente

espaçados e parênquima do tipo marginal; frequência e dimensões dos vasos são distintas, assim como agrupamento de vasos parecem ser distintos e *Cariniana estrellensis* apresenta parênquima reticulado. O segundo par apresenta um número menor de semelhanças: ambas espécies apresentam raios finos, porém *Goupia glabra* apresenta raios com menor espaçamento entre si; os vasos de ambas são solitários, com dimensões aparentemente próximas. Ambas apresentam zonas fibrosas demarcando as camadas de crescimento, apresentando um padrão intercalado de amplas “faixas”, mais contrastante em *Euxylophora paraensis* e mais sutil em *Goupia glabra*. Por último, as semelhanças entre *Goupia glabra* e *Bagassa guianensis* estão nos raios finos, mais ou menos regularmente espaçados, poros em sua grande maioria obstruídos, o que acentua o contraste com o fundo fibroso; apresentam suaves demarcações entre as camadas de crescimento. Contudo, as dimensões e frequências dos vasos são diferentes. Portanto, apesar de suas dissimilaridades, é possível conjecturar que provavelmente, neste caso, houve certa influência de características anatômicas para a confusão entre os espécimes.

FIGURA 27 – IMAGENS IDENTIFICADAS INCORRETAMENTE NO TESTE 4 – PARTE 3, GRUPO 1




FONTE: A autora (2024).

LEGENDA: Verdadeiras (A-C) e preditas (D-F). A: *Balfourodendron riedelianum*; B: *Euxylophora paraensis*; C: *Goupia glabra*; D: *Cariniana estrellensis*; E: *Goupia glabra*; F: *Bagassa guianensis*.

Ao analisar a fileira superior da Figura 28 é possível identificar algo em comum: as imagens A, B e C apresentam problemas tanto na aquisição das imagens (desfoque) como no preparo da superfície da madeira; em D, há a impressão de que a imagem “estourou” pelo excesso de luz. No duo *Hymenolobium petraeum* x *Mezilaurus itauba* há o contraste de um fundo escuro (fibras) com parênquima/vasos obstruídos. Ainda para este duo, ambos apresentam raios bem finos e, em certas porções, quase aparentam ter uma tendência a arranjo diagonal dos vasos. Este conjunto de características, mais o preparo não homogêneo da superfície e desfoque do equipamento podem representar um padrão semelhante o suficiente para ser interpretado erroneamente pelo modelo. Não é possível identificar os poros nas imagens de *Manilkara huberi* e *Handroanthus* sp., nem outros caracteres anatômicos com clareza. Contudo, devido à sua organização, é possível identificar em ambas finas linhas curtas que provavelmente são de parênquima (não necessariamente em linha) e o contraste (pouco) distinto com o fundo fibroso.

A maior parte da imagem de *Carapa guianensis* (Figura 28C) está desfocada e a superfície da peça apresenta arranhões. Contudo, ainda é possível enxergar padrões semelhantes entre ela e *Goupia glabra*, incluindo-se a frequência e dimensões dos vasos, formando quase um “pontilhismo” em contraste com as fibras. Por fim, a Figura 28D parece indicar um alto brilho/contraste e não apresenta semelhanças expressivas entre ambas que possam justificar a confusão entre elas.

FIGURA 28 – IMAGENS IDENTIFICADAS INCORRETAMENTE NO TESTE 4 – PARTE 3, GRUPO 2



FONTE: A autora (2024).

LEGENDA: Verdadeiras (A-D) e preditas (E-H). A: *Hymenolobium petraeum*; B: *Manilkara huberi*; C: *Carapa guianensis*; D: *Goupia glabra*; E: *Mezilaurus itauba*; F: *Handroanthus* sp.; G: *Goupia glabra*; H: *Cedrelinga cateniformis*.

Desconsiderando-se a parte 1 deste teste, a acurácia geral da parte 2 deste teste está ligeiramente acima dos 99,47% encontrada por Souza et al. (2020) e, tanto a parte 2 como a parte 3 estão acima dos de 97,77% relatada por Paula Filho et al. (2014), ambos com um número de classes menor do que o deste teste (46 e 41, respectivamente), além de Andrade, Basso e Latorraca (2020) que obtiveram melhor acurácia com valor de 97,7%.

Considerando-se as análises que utilizaram *mosaic* e *mixup* no Teste 4 em seu processamento, há pequena diferença na acurácia geral (menos de 0,5). Para o banco de dados aqui analisado, o fator preponderante para a escolha de cor ou escala de cinza nas imagens é a utilização de recursos já que a análise com imagens coloridas demorou praticamente uma hora a mais para o seu processamento, mesmo possuindo uma etapa a menos (conversão de imagem colorida para escala de cinza). Esta diferença temporal provavelmente ocorreu em razão da quantidade de caracteres que precisam ser processados (provavelmente o número é maior em imagens coloridas). Então, neste caso, a escolha pelo uso de imagens em escala de cinza é mais vantajosa por usar menos recursos computacionais, reduzindo seu custo.

É válido ressaltar que o balanceamento de classes foi um recurso valioso para o processamento dos dados, sendo a *data augmentation*, *mixup* e *mosaic*

imprescindíveis para os bons resultados obtidos em razão da amplitude entre as classes. Salienta-se que, independentemente do tamanho das amplitudes dos testes, as acurácias se mantiveram acima de 99%. Esses recursos, em conjunto com o *dropout* também foram determinantes para evitar o *overfitting* e permitir o aprendizado da rede.

Ao observar os resultados de todos os testes, em um primeiro momento, parece se destacar a importância da homogeneidade no preparo da superfície a ser fotografada, seguida pela manipulação do equipamento (especialmente estabilização) para que haja uma redução nos erros. Contudo, inúmeras imagens dentro dos bancos de dados analisados apresentam qualidade subótima ou até ruim, mas no “pior” resultado houveram 7 imagens (de 6 espécies distintas) erroneamente identificadas em um universo de mais de 10.000 imagens! Além deste formidável índice de acerto, esta não padronização afasta-se da “perfeição” esperada (ou o mais próximo disso) a partir da aplicação do método científico em situações laboratoriais (consideradas ótimas) e aproxima-se da aplicação prática, cotidiana e real das problemáticas e situações de campo que são caracterizadas por diversas fontes de variação (luz, equipamento, usuário, manuseio, irregularidades na superfície da amostra, diferentes aumentos, etc.) na identificação de madeiras e obtenção de imagens das amostras.

Os valores resultantes desse último teste indicam o potencial de YOLOv8m para a distinção de madeiras utilizando imagens macroscópicas da seção transversal, desde que, para o treinamento e validação do modelo, haja uma quantidade significativa de imagens por classe. Destaca-se a sua acurácia e poder preditivo em um banco com mais de 70 classes, incluindo-se mesmo gênero e família e diversas fontes de variação. Trinta e duas classes estão presentes em mais de um banco de dados, indicando que mesmo provenientes de equipamentos diferentes, diferentes fontes de iluminação, magnificação distinta e preparo de superfície, a técnica se mostrou eficiente. Mais uma vez, ao discutir sobre a produção de ciência, sabe-se que o controle das fontes de variação e a maior homogeneidade possível para realização de testes é preferível, contudo, em situações não laboratoriais, muitos desses métodos são inviáveis. Portanto, o processamento empregado neste estudo possui um grande potencial para o emprego em larga escala para identificação/distinção de

espécies de madeira utilizando-se de imagens macroscópicas obtidas em situações não laboratoriais ou em condições não perfeitas e não homogêneas.

Além da quantidade, é importante ressaltar a diversidade das imagens analisadas neste estudo em razão das diferentes fontes de alteração anatômica da estrutura da madeira, ainda necessitando-se de muitos esforços para a construção de um banco de dados global, de acesso livre e que pode ser alimentado por vários usuários mediante ao atendimento de diversos pré-requisitos.

Em âmbito nacional, esse banco de dados poderia ser alimentado em uma lógica hierárquica semelhante ao DOF, em que os órgãos ambientais estaduais alimentam uma plataforma nacional com as documentações de suas respectivas jurisdições. Contudo, um entrave antecederia esse fornecimento de dados: a correta identificação em campo. Por sua vez, isso poderia ser, ao menos parcialmente, contornado pela combinação deste sistema com uma segunda plataforma alimentada pelo Serviço Florestal Brasileiro e uma cooperação em rede entre laboratórios de anatomia da madeira no território nacional que forneceriam imagens de amostras corretamente identificadas por especialistas. Obviamente, a construção e aperfeiçoamento de tais sistemas se dariam ao longo do tempo, sendo necessários ajustes constantes que podem ser otimizados com a implementação de técnicas de aprendizado de máquina, especialmente aprendizado profundo e redes neurais convolucionais, destacando-se aqui a importância de uma equipe multidisciplinar para a idealização, design, construção e manutenção do sistema.

2.6 CONSIDERAÇÕES DO CAPÍTULO

Assim como na identificação tradicional, as características do parênquima e poros tem maior peso para a identificação e distinção de espécies, seguido da espessura dos raios na seção transversal e por último, coloração. Em casos em que essas características não se encontravam na mesma classe entre o duo verdadeira/predita, a proximidade na sua organização estabeleceu padrões semelhantes o suficiente para que imagens de espécies distintas fossem interpretados como da mesma classe.

É válido comentar que, neste estudo, imagens de madeiras sob diferentes níveis de ameaça e regulação, tanto nacional como internacional (*Bertholletia excelsa*, *Handroanthus* sp., *Swietenia macrophylla*, *Balfourodendron riedelianum*, *Euxylophora paraensis*) foram erroneamente identificadas como outras espécies (não ameaçadas/reguladas), impactando negativamente sua regulação e proteção. Porém, as ocorrências geralmente se restringiram a uma imagem erroneamente identificada por espécie (exceto para *Euxylophora paraensis*, com duas ocorrências no total de testes performados). Portanto, a quantidade de imagens corretamente identificadas dessas espécies compensa esse percentual de erro, pois seus benefícios para o cumprimento da legislação e conservação da fauna teriam um impacto tanto quantitativo como qualitativo maior.

Houve apenas uma ocorrência de espécie não regulada/ameaçada que foi confundida com uma espécie de alto valor e severa restrição (*Paubrasilia echinata*), além de única ocorrência de confusão entre espécies reguladas (a diferentes níveis), em que *Manilkara huberi* (*M. elata*) foi confundida com *Handroanthus* sp. Além das questões regulatórias supracitadas, a identificação incorreta de espécimes acarreta também no uso indevido ou em produto final com características e propriedades distintas do esperado, prejudicando o seu uso final e também reduzindo a confiança do consumidor no mercado/fornecedor.

A partir dos resultados deste estudo, é possível afirmar que YOLOv8m possui grande potencial para a identificação/distinção de madeiras no modo de classificação, já que em todos os testes a acurácia foi superior a 99%, mantendo para quase todas as classes métricas de precisão, *recall* e F1-score que também

atestam a precisão, sensibilidade e poder preditivo da técnica empregada. Em uma situação que boa parte das fontes de variação estejam controladas, essas métricas já seriam extremamente relevantes, contudo, são de maior valia quando resultantes da análise de imagens com algumas fontes de variação que geralmente não são controladas em situações cotidianas, como situações típicas de fiscalização.

O emprego de YOLOv8 tem como desvantagens a necessidade de conhecimentos computacionais (especialmente de programação) e estatísticos intermediários a avançados, além de custos com hardware para um processamento rápido e sem engasgos, especialmente para a construção do modelo. Para contornar algumas dessas problemáticas, existe a possibilidade do processamento e armazenamento em nuvem, podendo ser continuamente alimentado e melhorado, além de um maior uso de *transfer learning*.

REFERÊNCIAS

AN, H.; LIANG, Z.; QIN, M.; HUANG, Y.; XIONG, F.; ZENG, G. Wood defect detection based on the CWB-YOLOv8 algorithm. **Journal of Wood Science**, v. 70, n. 1, p. 26, 2024.

ANDRADE, B. G. **Visão computacional para identificação de espécies lenhosas em campo**. Tese de doutorado. 2020. 106f. Tese (Doutorado em Ciências Florestais e Ambientais) – Setor de Ciências Agrárias, Universidade Federal Rural do Rio de Janeiro, Seropédica (RJ), 2020. Disponível em: <https://tede.ufrj.br/jspui/bitstream/jspui/6024/2/2020%20-%20Bruno%20Geike%20de%20Andrade.pdf>. Acesso em: 03 nov. 2021.

ANDRADE, B. G.; BASSO, V. M.; LATORRACA, J. V. F. Machine vision for field-level wood identification. **IAWA Journal**, v. 41, n. 4, p. 681-698, 2020.

ARÉVALO, R.; PULIDO, R.; E. N.; SOLÓRZANO, G. J. F.; SOARES, R.; RUFFINATTO, F.; RAVINDRAN, P.; WIEDENHOEFT, A. C. Imaged based identification of Colombian timbers using the Xylotron: A proof of concept international partnership. **Colombia forestal**, v. 24, n. 1, p. 5-16, 2021.

ARPACI, S. S.; TOMAK, E. D.; ERMEYDAN, M. A.; YILDIRIM, I. Natural weathering of sixteen wood species: Changes on surface properties. **Polymer Degradation and Stability**, v. 183, p. 109415, 2021.

CASAS, G. G.; ISMAIL, Z. H.; LIMEIRA, M. M. C.; SILVA, A. A. L.; LEITE, H. G. Automatic detection and counting of stacked eucalypt timber using the YOLOv8 model. **Forests**, v. 14, n. 12, p. 2369, 2023.

CUI, Y.; LU, S.; LIU, S. Real-time detection of wood defects based on SPP-improved YOLO algorithm. **Multimedia Tools and Applications**, v. 82, n. 14, p. 21031-21044, 2023.

DZURENDA, L. Natural Variability of the color of beech wood in the color space CIE L* a* b. **Forests**, v. 14, n. 6, p. 1103, 2023.

ELFWING, S.; UCHIBE, E.; DOYA, K. Sigmoid-weighted linear units for neural network function approximation in reinforcement learning. **Neural networks**, v. 107, p. 3-11, 2018.

FANG, Y.; GUO, X.; CHEN, K.; ZHOU, Z.; YE, Q. Accurate and automated detection of surface knots on sawn timbers using YOLO-V5 model. **BioResources**, v. 16, n. 3, p. 5390, 2021.

GURĂU, L.; TIMAR, M. C.; COȘEREANU, C.; COSNITA, M.; STANCIU, M. D. Aging of wood for musical instruments: analysis of changes in color, surface morphology, chemical, and physical-acoustical properties during UV and thermal exposure. **Polymers**, v. 15, n. 7, p. 1794, 2023.

HAONAN, J.; HUADONG, X.; LIHAI, W.; JINSHENG, Z.; XIAOHUI, C.; XU, T. Quantitative identification of surface defects in wood paneling based on improved YOLOv5. **Journal of Beijing Forestry University**, v. 45, n. 4, p. 147-155, 2023.

HE, T.; LU, Y.; JIAO, L.; ZHANG, Y.; JIANG, X.; YIN, Y. Developing deep learning models to automate rosewood tree species identification for CITES designation and implementation. **Holzforschung**, v. 74, n.12, p.1123-1133, 2020.

HWANG, S.; 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, 2021.

InsideWood. 2004-onwards. Published on the Internet. <http://insidewood.lib.ncsu.edu/search>

JBRJ - Jardim Botânico do Rio de Janeiro. **Flora e Funga do Brasil**. Disponível em: <<https://floradobrasil.jbrj.gov.br/FB611636>>.

JOCHER, G.; CHAURASIA, A.; QIU, J. **YOLO by Ultralytics version: 8.0.0**. doi: 10.5281/zenodo.3908559. date-released: 2023-1-10. license: AGPL-3.0. <https://github.com/ultralytics/ultralytics>.

KROPAT, M.; HUBBE, M. A.; LALEICKE, F. Natural, accelerated, and simulated weathering of wood: A review. **BioResources**, v. 15, n. 4, p. 9998, 2020.

KURDTHONGMEE, W. A comparative study of the effectiveness of using popular DNN object detection algorithms for pith detection in cross-sectional images of parawood. **Heliyon**, v. 6, n. 2, 2020.

KURODA, K. Hardwood identification using a microcomputer and IAWA codes. **IAWA Bulletin**, v.8, p.69–77, 1987.

KWON, O.; LEE, H. G.; LEE, M. R.; JANG, S.; YANG, S.Y.; PARK, S.Y.; CHOI, I. G.; YEO, H. Automatic wood species identification of Korean softwood based on convolutional neural networks. **Journal of the Korean Wood Science and Technology**, v.45, n.6, p.797-808, 2017

LAPASHA, C.A.; WHEELER, E. A. A microcomputer-based system for computer-aided wood identification. **IAWA Bulletin**, v.8, p. 347–54, 1987.

LOPES J.R., D. V.; BOBADILHA, G. S.; GREBNER, K M. A fast and robust artificial intelligence technique for wood knot detection. **BioResources**, v. 15, n. 4, p. 9351, 2020.

MATSUO, M.; YOKOYAMA, M.; UMEMURA, K.; SUGIYAMA, J.; KAWAI, S.; GRIL, J.; KUBODERA, S.; MITSUTANI, T.; OZAKI, H.; SAKAMOTO, M.; IMAMURA, M. Aging of wood: Analysis of color changes during natural aging and heat treatment. **Holzforschung**, v. 65, n. 3, p. 361-368, 2011.

MENG, W.; YUAN, Y. SGN-YOLO: Detecting wood defects with improved YOLOv5 based on semi-global network. **Sensors**, v. 23, n. 21, p. 8705, 2023.

MOYA, R.; CALVO-ALVARADO, J. Variation of wood color parameters of *Tectona grandis* and its relationship with physical environmental factors. *Annals of Forest Science*, v. 69, p. 947-959, 2012.

PAULA FILHO, P. L.; OLIVEIRA, L. S.; NISGOSKI, S.; BRITTO JR., A. S. Forest Species Recognition using Macroscopic Images. **Machine Vision and Applications**, v. 25, n. 4, p. 1019-1031, 2014.

PEARSON, R. G.; WHEELER, E. A. Computer identification of hardwood species. **IAWA Bulletin**, v.2, p.37-40, 1981.

PHELPS, J. E.; MCGINNES, E. A.; GARRETT, H. E.; COX, G. S. Growth-quality evaluation of black walnut wood. Part II-color analyses of veneer produced on different sites. **Wood and Fiber Science**, p. 177-185, 1983.

PyTorch. ADAMW, 2023. Disponível em: <
<https://pytorch.org/docs/stable/generated/torch.optim.AdamW.html> >.

RangeKing. Brief summary of YOLOv8 model structure. 2023.
<https://github.com/ultralytics/ultralytics/issues/189>.

RAVINDRAN, P.; OWENS, F. C.; WADE, A. C.; SHMULSKY, R.; WIEDENHOEFT, A. C. Towards sustainable North American wood product value chains, part I: Computer vision identification of diffuse porous hardwoods. **Frontiers in Plant Science**, v. 12, p. 758455, 2022a.

RAVINDRAN, P.; WADE, A. C.; OWENS, F. C.; SHMULSKY, R.; WIEDENHOEFT, A. C. Towards sustainable North American wood product value chains, part II: Computer vision identification of ring-porous hardwoods." **Canadian Journal of Forest Research**, v.52, n.7, p. 1014-1027, 2022b.

RAVINDRAN, P.; WIEDENHOEFT, A. C. Caveat emptor: on the need for baseline quality standards in computer vision wood identification. **Forests**, v. 13, n.4, p. 632, 2022.

RÜTHER, P.; JELLE, B. P. Color changes of wood and wood-based materials due to natural and artificial weathering. **Wood Material Science & Engineering**, v. 8, n. 1, p. 13-25, 2013.

SOTELO MONTES, C.; WEBER, J. C.; GARCIA, R. A.; SILVA, D. A.; MUÑIZ, G. I. B. Variation in wood color among natural populations of five tree and shrub species in the Sahelian and Sudanian ecozones of Mali. **Canadian Journal of Forest Research**, v. 43, n. 6, p. 552-562, 2013.

SOUZA, D.V.; SANTOS, J. X.; VIEIRA, H. C.; NAIDE, T. L.; NISGOSKI, S.; OLIVEIRA, L. E. S. An automatic recognition system of Brazilian flora species

based on textural features of macroscopic images of wood. **Wood Science and Technology**, v. 54, p.1065–1090, 2020.

SUN, Y.; LIN, Q.; HE, X.; ZHAO, Y.; DAI, F.; QIU, J.; CAO, Y. Wood species recognition with small data: A deep learning approach. **International Journal of Computational Intelligence Systems**, v.14, n.1, p.1451-1460, 2021.

TRAORÉ, M.; KAAL, J.; CORTIZAS, A. M. Variation of wood color and chemical composition in the stem cross-section of oak (*Quercus* spp.) trees, with special attention to the sapwood-heartwood transition zone. **Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy**, v. 285, p. 121893, 2023.

TSANG, S. Brief Review — **SiLU: Sigmoid-weighted Linear Unit**. Medium. 2022. Disponível em: <<https://sh-tsang.medium.com/review-silu-sigmoid-weighted-linear-unit-be4bc943624d>>.

ULTRALYTICS. **Ultralytics YOLOv8 Docs**. 2023. Disponível em:<<https://docs.ultralytics.com/datasets/detect/coco/>>.

WANG, B.; YANG, C.; DING, Y.; QIN, G. Detection of wood surface defects based on improved YOLOv3 Algorithm. **BioResources**, v. 16, n. 4, 2021.

WANG, M.; LI, M.; CUI, W.; XIANG, X.; DUO, H. TSW-YOLO-v8n: Optimization of detection algorithms for surface defects on sawn timber. **BioResources**, v. 18, n. 4, p. 8444, 2023.

WU, F.; GAZO, R.; HAVIAROVA, E.; BENES, B. Wood identification based on longitudinal section images by using deep learning. **Wood Science and Technology**, v. 55, p. 553-563, 2021.

YUSOF, R.; KHALID, M.; KHAIRUDDIN, A. S. M. Fuzzy data management on pores arrangement for tropical wood species recognition system. **Science and Information Conference**, London, UK, 2013, pp. 529-535.

ZHANG, P.; WANG, Z.; RAO, Y.; ZHENG, J.; ZHANG, N; WANG, D; ZHU, J; FANG, Y.; GAO, X. Identification of pine wilt disease infected wood using UAV RGB imagery and improved YOLOv5 models integrated with attention mechanisms. **Forests**, v. 14, n. 3, p. 588, 2023.

ZHENG, Y.; WANG, M.; ZHANG, B.; SHI, X.; CHANG, Q. GBCD-YOLO: A high-precision and real-time lightweight model for wood defect detection. **IEEE Access**, v. 12, p. 12853 - 12868, 2024.

ZHAO, Z.; YANG, X.; GE, Z.; GUO, H.; ZHOU, Y. Wood microscopic image identification method based on convolution neural network. **BioResources**, v. 16, n. 3, 2021.

ZHOU, S.; ZHU, H.; LIU, X.; HU, Q.; LU, H.; PENG, Z. Wood Surface Defect Detection Based on Improved YOLOv8s. **IAENG International Journal of Computer Science**, v. 51, n. 3, 2024.

CONSIDERAÇÕES FINAIS

O estado da arte estabelecido neste trabalho indica o Brasil e Estados Unidos como os países de vanguarda para o desenvolvimento de técnicas e tecnologias para a identificação/distinção de madeiras utilizando-se de redes neurais convolucionais, algo que pode ser reflexo da importância desses dois países no cenário florestal mundial. A utilização de aprendizado de máquina para fins de identificação de madeira já é explorada há algumas décadas, contudo, o rápido avanço das tecnologias indica que ainda existe muito potencial para ser explorado, especialmente em aplicações interdisciplinares.

YOLOv8m-cls possui grande potencial para a identificação/distinção de espécies de madeira por meio de imagens macroscópicas, obtendo resultados promissores inclusive para espécies com grande semelhança anatômica ou pertencentes ao mesmo gênero.

Além do uso de YOLOv8 para identificação/distinção de madeiras, esse trabalho traz como inovação um banco de dados de imagens de espécies da Caatinga, bioma de importância ecológica, social e econômica, mas que ainda apresenta lacunas de conhecimento. Ademais, este é um dos poucos estudos que reúne espécies da Caatinga, Amazônia e Mata Atlântica, além de algumas espécies exóticas de importância comercial, para sua identificação por meio de imagens macroscópicas.

Como trabalhos futuros indica-se a expansão do banco de dados (tanto em quantidade de espécies como diferentes preparos de superfície e equipamentos de obtenção, obtenção de acesso a outros bancos já existentes, aplicações online, offline e em equipamentos portáteis); testar eficiência de YOLOv8 para imagens microscópicas e testar quantidades mínimas de imagens para a construção de um bom modelo para identificação/distinção de madeiras com YOLOv8m. Também pode-se comparar as diferentes versões do YOLO já lançadas para fins de classificação. Pensando mais adiante, também é interessante explorar a construção de um *software* utilizando-se de YOLOv8 para o processamento com uma interface simples para a entrada de imagens por um operador leigo e que funcione de maneira online e offline.

Por fim, mesmo com todos os avanços tecnológicos conhecidos até o presente estudo, um especialista em anatomia continua sendo indispensável

para a cadeia de identificação de espécies, pois é a partir dele que serão introduzidas as imagens corretamente identificadas para o treinamento de qualquer modelo.

REFERÊNCIAS GERAIS

- AHONEN, T.; HADID, A.; PIETIKAINEN, M. Face description with local binary patterns: Application to face recognition. **IEEE Transaction Pattern Analysis and Machine Intelligence**, v. 28, n. 12, p. 2037–2041, 2006.
- ALTMAN, N. S. An Introduction to kernel and nearest neighbor nonparametric regression. **The American Statistician**, n. 46, p. 175-185, 1992.
- AN, H.; LIANG, Z.; QIN, M.; HUANG, Y.; XIONG, F.; ZENG, G. Wood defect detection based on the CWB-YOLOv8 algorithm. **Journal of Wood Science**, v. 70, n. 1, p. 26, 2024.
- ANDRADE, B. G. **Visão computacional para identificação de espécies lenhosas em campo**. Tese de doutorado. 2020. 106f. Tese (Doutorado em Ciências Florestais e Ambientais) – Setor de Ciências Agrárias, Universidade Federal Rural do Rio de Janeiro, Seropédica (RJ), 2020. Disponível em: <https://tede.ufrrj.br/jspui/bitstream/jspui/6024/2/2020%20-%20Bruno%20Geike%20de%20Andrade.pdf>. Acesso em: 03 nov. 2021.
- ANDRADE, B. G.; BASSO, V. M.; LATORRACA, J. V. F. Machine vision for field-level wood identification. **IAWA Journal**, v. 41, n. 4, p. 681-698, 2020.
- ARÉVALO, R.; PULIDO, R.; E. N.; SOLÓRZANO, G. J. F.; SOARES, R.; RUFFINATTO, F.; RAVINDRAN, P.; WIEDENHOEFT, A. C. Imaged based identification of Colombian timbers using the Xylotron: A proof of concept international partnership. **Colombia forestal**, v. 24, n. 1, p. 5-16, 2021.
- ARIA, M.; CUCCURULLO, C. Bibliometrix: An R-tool for comprehensive science mapping analysis. **Journal of Informetrics**, v.11, n.4, pp 959-975, 2017.
- ARPACI, S. S.; TOMAK, E. D.; ERMEYDAN, M. A.; YILDIRIM, I. Natural weathering of sixteen wood species: Changes on surface properties. **Polymer Degradation and Stability**, v. 183, p. 109415, 2021.
- BENGIO, Y.; COURVILLE, A.; VINCENT, P. Representation learning: a review and new perspectives. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, n. 35, p. 1798–1828, 2013.
- BISHOP C.M. **Pattern Recognition and Machine Learning**. New York: Springer-Verlag, 2006. 758p.
- BLOKLAND, J.; NASIR, V.; COOL, J.; AVRAMIDIS, S.; ADAMOPOULOS, S. Machine learning-based prediction of internal checks in weathered thermally modified timber. **Construction and Building Materials**, v. 281, p. 122193, 2021.
- BOCHKOVSKIY, A.; WANG, C-Y.; LIAO, H-Y. YOLOv4: Optimal Speed and Accuracy of Object Detection. arXiv preprint arXiv:2004.10934, 2020.

BRANDT, J. S.; NOLTE, C; AGRAWAL, A. Deforestation and timber production in Congo after implementation of sustainable forest management policy. **Land Use Policy**, v 52, p.15-22, 2016.

BRIECHLE, S.; KRZYTEK, P.; VOSSELMAN, G. Silvi-Net—A dual-CNN approach for combined classification of tree species and standing dead trees from remote sensing data. **International Journal of Applied Earth Observation and Geoinformation**, v. 98, p. 102292, 2021.

BURGES, C. J. C. A tutorial on support vector machines for pattern recognition. **Data Mining and Knowledge Discovery**, v. 2, p. 121-167, 1998.

CASAS, G. G.; ISMAIL, Z. H.; LIMEIRA, M. M. C.; SILVA, A. A. L. da; LEITE, H. G. Automatic detection and counting of stacked eucalypt timber using the Yolov8 model. **Forest**, v. 14, n. 12, p. 2369, 2023.

CHANG, C. C.; LIN, C. J. LIBSVM: A library for support vector machines. **ACM Transactions on Intelligent Systems and Technology**, v. 2, p. 27, 2011.
CHEN, J.; WANG, L.; LI, L.; MAGALHÃES, J.; SONG, W.; LU, W.; XIONG, L.; CHANG, W-Y.; SUN, Y. Effect of forest certification on international trade in forest products. **Forests**, v. 11, n. 12, 1270, 2020.

CHEN, S.; SHIINA, R.; NAKAI, K.; AWANO, T.; YOSHINAGA, A.; SUGIYAMA, J. Potential of machine learning approaches for predicting mechanical properties of spruce wood in the transverse direction. **Journal of Wood Science**, v. 69, n. 1, p. 22, 2023.

CLAUSI, D.A. An analysis of co-occurrence texture statistics as a function of gray level quantization. **Canadian Journal of Remote Sensing**, v. 28, n. 1, p. 45-62, 2002.

CORTES, C.; VAPNIK, V. Support-vector networks. **Machine Learning**, n. 20, p. 273–297, 1995.

COVER, T.; HART, P. Nearest neighbor pattern classification. **IEEE Transactions on Information Theory**, n. 13, p. 21-27, 1967.

CUI, Y.; LU, S.; LIU, S. Real-time detection of wood defects based on SPP-improved YOLO algorithm. **Multimedia Tools and Applications**, v. 82, n. 14, p. 21031-21044, 2023.

CUNI-SANCHEZ, A. et al. High aboveground carbon stock of African tropical montane forests. **Nature**, v. 596, n.7873, p. 536-542, 2021.

DAVIS, J.; GOADRICH, M. The relationship between precision-recall and ROC curves. **Proceedings of the 23rd International Conference on Machine Learning**, 2006.

DE WASSEIGE, C.; TADOUM, M.; EBAA-ATYI, R.; DOUMENGE, C. **The forests of the Congo Basin-Forests and climate change**. Technical report, 2015.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**. Wiley-Interscience, 2000. 738p.

DZURENDA, L. Natural Variability of the color of beech wood in the color space CIE L* a* b. **Forests**, v. 14, n. 6, p. 1103, 2023.

ELFWING, S.; UCHIBE, E.; DOYA, K. Sigmoid-weighted linear units for neural network function approximation in reinforcement learning. **Neural networks**, v. 107, p. 3-11, 2018.

ESPINOZA, O. Trends in the US forest products sector, markets, and technologies. In: Dockry, M. J.; Bengston, D. N.; Westphal, L. M., comps. **Drivers of change in US forests and forestry over the next 20 years**. P. 26-49, 2020.

FALAGAS, M. E.; PITSOUNI, E. I.; MALIETZIZ, G. A.; PAPPAS, G. Comparison of PubMed, Scopus, web of science, and Google scholar: strengths and weaknesses. **The FASEB Journal**, v. 22, n. 2, p. 338-342, 2008.

FAN, J.; LIU, Y.; HU, Z. K.; ZHAO, Q.; SHEN, L. X.; ZHOU, X. L. Solid wood panel defect detection and recognition system based on faster R-CNN. **Journal of Forestry Engineering**, v. 4, n. 3, p. 112-117, 2019.

FANG, Y.; GUO, X.; CHEN, K.; ZHOU, Z.; YE, Q. Accurate and automated detection of surface knots on sawn timbers using YOLO-V5 mode. **BioResources**, v. 16, n. 3, p. 5390-5406, 2021.

FAO. **The state of the world's forests**. 2021.

FAWCETT, T. An introduction to ROC analysis. **Pattern Recognition Letters**, v. 27, n. 8, p.862-874, 2006.

GALAR, D.; GUSTAFSON, A.; TORMOS, B.; BERGES, L. Maintenance decision making based on different types of data fusion. **Eksplatacja i Niezawodnosc – Maintenance and Reliability**, v. 14, n. 2, p. 135–144, 2012.

GASPARYAN, A. Y.; AYVAZYAN, L.; BLAKMORE, H.; KITAS, G. D. Writing a narrative biomedical review: considerations for authors, peer reviewers, and editors. **Rheumatology international**, v. 31, p. 1409-1417, 2011.

GEUS, A. R., SILVA, S. F., GONTIJO, A. B., SILVA, F. O., BATISTA, M. A., SOUZA, J. R. An analysis of timber sections and deep learning for wood species classification. **Multimedia Tools and Applications**, v.79, n.45, p.34513-34529, 2020.

GOODFELLOW, I.; COURVILLE, A.; BENGIO, Y. **Deep Learning**. MIT Press, Cambridge, 2016. 775p.

GRAVES, A.; MOHAMED, A.-R.; HINTON, G. E. Speech recognition with deep recurrent neural networks. **IEE International Conference on Acoustics, Speech and Signal Processing**, p. 6645-6649, 2013.

GUO, Y.; WANG, W.; LIN, Q.; WANG, H.; WENG, J.; CHEN, W. Automatic recognition and calculation of softwood ray height based on tangential section images by using YOLOv5. In: **2023 China Automation Congress (CAC)**. IEEE, 2023. p. 7116-7121.

GURĂU, L.; TIMAR, M. C.; COȘEREANU, C.; COSNITA, M.; STANCIU, M. D. Aging of wood for musical instruments: analysis of changes in color, surface morphology, chemical, and physical-acoustical properties during UV and thermal exposure. **Polymers**, v. 15, n. 7, p. 1794, 2023.

HAONAN, J.; HUADONG, X.; LIHAI, W.; JINSHENG, Z.; XIAOHUI, C.; XU, T. Quantitative identification of surface defects in wood paneling based on improved YOLOv5. **Journal of Beijing Forestry University**, v. 45, n. 4, p. 147-155, 2023.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. **IEEE Transactions on Systems, Man, and Cybernetics**, v. SMC-3, n. 6, p. 610-621, 1973.

HAWKINS, D. M. The Problem of Overfitting. **Journal of chemical information and computer sciences**, v. 44, n. 1, p. 1-12, 2004.

HAYKIN, S. **Neural networks and learning machines**. Prentice Hall/Pearson, New York, 2009.938p.

HE, T.; LU, Y.; JIAO, L.; ZHANG, Y.; JIANG, X.; YIN, Y. Developing deep learning models to automate rosewood tree species identification for CITES designation and implementation. **Holzforschung**, v. 74, n.12, p.1123-1133, 2020.

HEIKKILÄ, M.; PIETKÄINEN, M.; SCHMID, C. Description of interest regions with local binary patterns. **Pattern Recognition**, v. 42, n. 3, p. 425-436, 2009.

HUANG, J.; HE, J.; GUAN, Y.; ZHANG, H. Real-time forest fire detection by ensemble lightweight YOLOX-L and defogging method. **Sensors**, v. 23, n. 4, p. 1894, 2023.

HWANG, S.; 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, 2021.

IBÁ. **Relatório técnico anual**: ano de referência 2020. 2021.

IBÁ. **Relatório técnico anual**: ano de referência 2022. 2023.

InsideWood. 2004-onwards. Published on the Internet.

<http://insidewood.lib.ncsu.edu/search>

JBRJ - Jardim Botânico do Rio de Janeiro. **Flora e Funga do Brasil**.

Disponível em: <<https://floradobrasil.jbrj.gov.br/FB611636>>.

JOCHER, G.; CHAURASIA, A.; QIU, J. **YOLO by Ultralytics version: 8.0.0**.

doi: 10.5281/zenodo.3908559. date-released: 2023-1-10. license: AGPL-3.0.

<https://github.com/ultralytics/ultralytics>.

JORDAN, M. I.; MITCHELL, T. M. Machine learning: trends, perspectives, and prospects. **Science**, v. 349, n. 6245, p.255-260, 2015.

KANAYAMA, H.; MA, T.; TSUCHIKAWA, S.; INAGAKI, T. Cognitive spectroscopy for wood species identification: near infrared hyperspectral imaging combined with convolutional neural networks. **Analyst**, v.144, n.21, p. 6438-6446, 2019.

KATTENBORN, T.; LEITLOFF, J.; SCHIEFER, F.; HINZ, S. Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. **ISPRS journal of photogrammetry and remote sensing**, v. 173, p. 24-49, 2021.

KHUDZARI, J.; KURIAN, J.; TARTAKOVKY, B.; RAGHAVAN, G. S. V. Bibliometric analysis of global research trends on microbial fuel cells using Scopus database. **Biochemical Engineering Journal**, v. 136, p. 51-60, 2018.

KIKUTA, K. The environmental costs of civil war: a synthetic comparison of the Congolese forests with and without the Great War of Africa. **The Journal of Politics**, v.82, n.4, p.1243-1255, 2020.

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

KROPAT, M.; HUBBE, M. A.; LALEICKE, F. Natural, accelerated, and simulated weathering of wood: A review. **BioResources**, v. 15, n. 4, p. 9998, 2020.

KULKARNI, A. V.; AZIZ, B.; SHAMS, I.; BUSSE, J. W. Comparisons of citations in Web of Science, Scopus, and Google Scholar for articles published in general medical journals. **Jama**, v. 302, n. 10, p. 1092-1096, 2009.

KURDTHONGMEE, W. A comparative study of the effectiveness of using popular DNN object detection algorithms for pith detection in cross-sectional images of parawood. **Heliyon**, v. 6, n. 2, 2020.

KURDTHONGMEE, W.; SUWANNARAT, K. Locating wood pith in a wood stem cross sectional image using YOLO object detection. **International Conference on Technologies and Applications of Artificial Intelligence**, 2019.

KURODA, K. Hardwood identification using a microcomputer and IAWA codes. **IAWA Bulletin**, v.8, p.69–77, 1987.

KWON, O.; LEE, H. G.; LEE, M. R.; JANG, S.; YANG, S.Y.; PARK, S.Y.; CHOI, I. G.; YEO, H. Automatic wood species identification of Korean softwood based on convolutional neural networks. **Journal of the Korean Wood Science and Technology**, v.45, n.6, p.797-808, 2017.

LAPASHA, C.A.; WHEELER, E. A. A microcomputer-based system for computer-aided wood identification. **IAWA Bulletin**, v.8, p. 347–54, 1987.
LAWSON, S. Illegal logging in the Democratic Republic of the Congo. **Energy, Environment and Resources EER** (2014): 2014.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep Learning. **Nature**, n. 521, p. 436-444, 2015.

LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, p. 2278-2324, 1998.

LENS, F.; LIANG, C.; GUO, Y.; TANG, X.; JAHANBANIFARD, M.; da SILVA, F. S. C.; CECCANTINI, G.; VERBEEK, F. J. Computer-assisted timber identification based on features extracted from microscopic wood sections. **IAWA Journal**, v. 41, n. 4, p. 660-680, 2020.

LIU, Z.; ZHANG, K.; WANG, C.; HUANG, S. Research on the identification method for the forest fire based on deep learning. **Optik**, v. 223, p. 165491, 2020.

LOPES J.R., D. V.; BOBADILHA, G. S.; GREBNER, K M. A fast and robust artificial intelligence technique for wood knot detection. **BioResources**, v. 15, n. 4, p. 9351, 2020.

MARTÍN-MARTÍN, A.; ORDUNA-MALEA, E.; THELWALL, M.; LÓPEZ-CÓZAR, E. D. Google Scholar, Web of Science, and Scopus: A systematic comparison of citations in 252 subject categories. **Journal of Informetrics**, v. 12, n. 4, p. 1160-1177, 2018.

MATSUO, M.; YOKOYAMA, M.; UMEMURA, K.; SUGIYAMA, J.; KAWAI, S.; GRIL, J.; KUBODERA, S.; MITSUTANI, T.; OZAKI, H.; SAKAMOTO, M.; IMAMURA, M. Aging of wood: Analysis of color changes during natural aging and heat treatment. **Holzforschung**, v. 65, n. 3, p. 361-368, 2011.

MCCONNELL, T. E.; TANGER, S. M.; JAMES, E. H. International trade's contributions to the United States forest sector and its import–export chain. **Journal of Forestry**, v. 117, n. 3, 210-225, 2019.

MCGINLEY, K. A.; GULDIN, R. W.; CUBBAGE, F. W. Forest sector research and development capacity. **Journal of Forestry**, v. 117, n. 5, p. 443-461, 2019.

MENG, W.; YUAN, Y. SGN-YOLO: detecting wood defects with improved YOLOv5 based on semi-global network. **Sensors**, v. 23, n. 21, 8705, 2023.

MIKOLAJCZYK, K.; SCHMID, C. A performance evaluation of local descriptors. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 27, n. 10, p. 1615-1630, 2005.

MOED, H. F. New developments in the use of citation analysis in research evaluation. **Archivum immunologiae et therapeuticae experimentalis**, v. 57, p. 13-18, 2009.

MONTOYA, F. G.; ALCAYDE, A.; BAÑOS, R.; MANZANO-AGUGLIARO, F. A fast method for identifying worldwide scientific collaborations using the Scopus database. **Telematics and Informatics**, v. 35, p. 168-185, 2018.

MOYA, R.; CALVO-ALVARADO, J. Variation of wood color parameters of *Tectona grandis* and its relationship with physical environmental factors. *Annals of Forest Science*, v. 69, p. 947-959, 2012.

NASI, R.; PUTZ, F. E.; PACHECO, P.; WUNDER, S.; ANTA, S. Sustainable forest management and carbon in tropical Latin America: the case for REDD+. **Forests**, v. 2, p. 200–217, 2011.

NASIR, V.; FATHI, H.; FALLAH, A.; KAZERIMAD, S.; SASSANI, F.; ANTOV, P. Prediction of mechanical properties of artificially weathered wood by color change and machine learning. **Materials**, v. 14, n. 21, p. 6314, 2021.

NEYSES, B.; SCHARF, A. Using machine learning to predict the density profiles of surface-densified wood based on cross-sectional images. **European Journal of Wood and Wood Products**, v. 80, n. 5, p. 1121-1133, 2022.

OJALA, T.; PIETIKAINEN, M.; MAENPAA, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 24, n. 7, p. 971-987, 2002.

PAN, S. J.; YANG, Q. A survey on transfer learning. **IEEE Transactions on Knowledge and Data Engineering**, v. 22, n. 10, p.1345–59, 2010.

PATRO, P.; MISRA, D. P. Registering and reporting systematic reviews. **Central Asian Journal of Medical Hypotheses and Ethics**, v.1, n.2, p.122-126, 2020.

PAULA FILHO, P. L.; OLIVEIRA, L. S.; NISGOSKI, S; BRITTO JR., A. S. Forest Species Recognition using Macroscopic Images. **Machine Vision and Applications**, v. 25, n. 4, p. 1019-1031, 2014.

PEARSON, R. G.; WHEELER, E. A. Computer identification of hardwood species. **IAWA Bulletin**, v.2, p.37–40, 1981.

PHELPS, J. E.; MCGINNES, E. A.; GARRETT, H. E.; COX, G. S. Growth-quality evaluation of black walnut wood. Part II-color analyses of veneer produced on different sites. **Wood and Fiber Science**, p. 177-185, 1983.

POWERS, D. M. W. Evaluation: from precision, recall and f-measure to ROC, informedness, markedness & correlation. **International Journal of Machine Learning Technology**, v. 2, n. 1, p.37-63, 2011.

PRASCHL, C.; PONTNER, A.; BOUMGARTNER, D.; ZWETTLER, G. A. Imaging framework: an interoperable and extendable connector for image-related Java frameworks. **SoftwareX**, v. 16, 100863, 2021.

PyTorch. ADAMW, 2023. Disponível em: <
<https://pytorch.org/docs/stable/generated/torch.optim.AdamW.html>>.

R Core Team (2023). R: A Language and environment for statistical computing. R foundation for statistical computing, Vienna, Austria. <<https://www.R-project.org/>>.

RAHIMI, S.; NASIR, V.; AVRAMIDIS, S.; SASSANI, F. The role of drying schedule and conditioning in moisture uniformity in wood: A machine learning approach. **Polymers**, v. 15, n. 4, p. 792, 2023.

RangeKing. Brief summary of YOLOv8 model structure. 2023.
<https://github.com/ultralytics/ultralytics/issues/189>.

RAVINDRAN, P.; OWENS, F. C.; WADE, A. C.; SHMULSKY, R.; WIEDENHOEFT, A. C. Towards sustainable North American wood product value chains, part I: Computer vision identification of diffuse porous hardwoods. **Frontiers in Plant Science**, v. 12, p. 758455, 2022.

RAVINDRAN, P.; OWENS, F. C.; WADE, A. C.; VEGA, P.; MONTENEGRO, R.; WIEDENHOEFT, A. C. Field-deployable computer vision wood identification of Peruvian timbers. **Frontiers in Plant Science**, v. 12, p. 647515, 2021.

RAVINDRAN, P.; WADE, A. C.; OWENS, F. C.; SHMULSKY, R.; WIEDENHOEFT, A. C. Towards sustainable North American wood product value chains, part II: Computer vision identification of ring-porous hardwoods." **Canadian Journal of Forest Research**, v.52, n.7, p. 1014-1027, 2022b.

RAVINDRAN, P.; WIEDENHOEFT, A. C. Caveat emptor: on the need for baseline quality standards in computer vision wood identification. **Forests**, v. 13, n.4, p. 632, 2022.

RAZAVIAN, A. S.; AZIZPOUR, H.; SULLIVAN, J.; CARLISSON, S. CNN features off-the-shelf: an astounding baseline for recognition. **IEEE Conference on Computer Vision and Pattern Recognition**, 2014.

REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHARDI, A. You only look once: unified, real-time object detection. **IEEE Conference on Computer Vision and Pattern Recognition**, 2016.

REDMON, J.; FARHADI, A. YOLOv3: An Incremental Improvement. **Computer Science**, arXiv: 1804.02767, 2018.

RICCI, F.; ROKACH, L.; SHAPIRA, B. **Recommender systems: introduction and challenges**, pp.1-34. Springer Link, 2015.

ROSLI, N. R.; KHAIRUDDIN, U.; FATHI, M. F. N.; KHAIRUDDIN, A. S. M.; AHMAD, A. Real-Time KenalKayu System with YOLOv3. In: **Advances in Robotics, Automation and Data Analytics: Selected Papers from iCITES 2020**. Springer International Publishing, 2021. p. 224-232.

RÜTHER, P.; JELLE, B. P. Color changes of wood and wood-based materials due to natural and artificial weathering. **Wood Material Science & Engineering**, v. 8, n. 1, p. 13-25, 2013.

SAITO, T.; REHMSMEIER, M. The Precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. **PLoS ONE**, v. 10, n. 3, e0118432, 2015.

SANTOSA, S.; SANTOSA, Y. Wood types classification using back-propagation neural network based on genetic algorithm with gray level co-occurrence matrix for features extraction. **IAENG International Journal of Computer Science**, v.46, n.2, p. 149-155, 2019.

SARKAR, N.; CHAUDHURI, B. B. An efficient differential box counting to compute fractal dimension of image. **IEEE Transactions on Systems Man and Cybernetics**, n. 24, p.115-120, 1994.

SCHÖLKOPF, B.; PLATT, J. C.; SHAWE-TAYLOR, J.; SMOLA, A. J.; WILIAMSON, R. C. Estimating the support of a high dimensional distribution. **Neural Computation**, v. 13, n.7, p. 1443-1471, 2001.

SCHUBERT, M.; KLÄUSLER, O. Applying machine learning to predict the tensile shear strength of bonded beech wood as a function of the composition of polyurethane prepolymers and various pretreatments. **Wood Science and Technology**, v. 54, n. 1, p. 19-29, 2020.

SILVA, C. A.; GUERRISI, G.; DEL FRATE, F.; SANO, E. E. Near-real time deforestation detection in the Brazilian Amazon with Sentinel-1 and neural networks. **European Journal of Remote Sensing**, 55:1, 129-149, 2022a.

SILVA, J. L.; BORDALO, R.; PISSARA, J.; PALACIOS, P. Computer vision-based wood identification: A review. **Forests**, v. 13, n. 12, p. 2041, 2022b.

SILVA, T. C.; ARAUJO, E. C. G.; LINS, T. R. S.; REIS, C. A.; SANQUETA, C. R.; ROCHA, M. P. Non-timber forest products in Brazil: a bibliometric and a state-of-the-art review. **Sustainability**, v. 12, n. 17, p. 7151, 2020.

SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. **Proceedings of the ICLR 2015**, p. 1-14, 2015.

SOKOLOVA, M.; LAPALME, G. A systematic analysis of performance measures for classification tasks. **Information Processing & Management**, v. 45, n. 4, p. 427-437, 2009.

SOTELO MONTES, C.; WEBER, J. C.; GARCIA, R. A.; SILVA, D. A.; MUÑIZ, G. I. B. Variation in wood color among natural populations of five tree and shrub species in the Sahelian and Sudanian ecozones of Mali. **Canadian Journal of Forest Research**, v. 43, n. 6, p. 552-562, 2013.

SOUZA, D.V.; SANTOS, J. X.; VIEIRA, H. C.; NAIDE, T. L.; NISGOSKI, S.; OLIVEIRA, L. E. S. An automatic recognition system of Brazilian flora species based on textural features of macroscopic images of wood. **Wood Science and Technology**, v. 54, p.1065–1090, 2020.

SUGIARTO, B.; GOJALI, E. A.; HERLAN, H.; LESTARI, P. A smartphone-based of wood identification using image feature extraction. **Journal of Computer Science and Informatics Engineering**, v. 4, n. 1, p. 9-15, 2020.

SUN, P. Wood quality defect detection based on deep learning and multicriteria framework. **Mathematical Problems in Engineering**, v. 2022, p. 1-9, 2022.

SUN, Y.; LIN, Q.; HE, X.; ZHAO, Y.; DAI, F.; QIU, J.; CAO, Y. Wood species recognition with small data: A deep learning approach. **International Journal of Computational Intelligence Systems**, v.14, n.1, p.1451-1460, 2021.

TRAORÉ, M.; KAAL, J.; CORTIZAS, A. M. Variation of wood color and chemical composition in the stem cross-section of oak (*Quercus* spp.) trees, with special attention to the sapwood-heartwood transition zone. **Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy**, v. 285, p. 121893, 2023.

TSANG, S. Brief Review — **SiLU: Sigmoid-weighted Linear Unit**. Medium. 2022. Disponível em: <<https://sh-tsang.medium.com/review-silu-sigmoid-weighted-linear-unit-be4bc943624d>>.

TURHAN, K.; SERDAR, B. Support vector machines in wood identification: the case of three *Salix* species from Turkey. **Turkish Journal of Agriculture and Forestry**, v. 37, n. 2, p. 249-256, 2013.

ULTRALYTICS. **Ultralytics YOLOv8 Docs**. 2023. Disponível em:<<https://docs.ultralytics.com/datasets/detect/coco/>>.

URBONAS, A.; RAUDONIS, V.; MASKELIŪNAS, R.; DAMAŠEVIČIUS, R. Automated identification of wood veneer surface defects using faster region-

based convolutional neural network with data augmentation and transfer learning. **Applied Sciences**, v. 9, n. 22, p. 4898, 2019.

VIEIRA, G. L. S.; PONTE, M. J. M. da; MOUTINHO, V. H. P.; JARDIM-GONÇALVES, R.; LIMA, C. P.; VINAGRE, M. V. A. Identification of wood from the Amazon by characteristics of Haralick and Neural Network: image segmentation and polishing of the surface. **iForest-Biogeosciences and Forestry**, v.15, n.4, p. 234-239, 2022.

WANG, B.; YANG, C.; DING, Y.; QIN, G. Detection of wood surface defects based on improved YOLOv3 Algorithm. **BioResources**, v. 16, n. 4, 2021.
WANG, M.; LI, M.; CUI, W.; XIANG, X.; DUO, H. TSW-YOLO-v8n: Optimization of detection algorithms for surface defects on sawn timber. **BioResources**, v. 18, n. 4, p. 8444, 2023.

WANG, Z.; LI, P.; CUI, Y.; LEI, S.; JANG, Z. Automatic detection of individual trees in forests based on airborne LiDAR data with a tree region-based convolutional neural network (RCNN). **Remote Sensing**, v. 15, n. 4, p. 1024, 2023.

WU, F.; GAZO, R.; HAVIAROVA, E.; BENES, B. Wood identification based on longitudinal section images by using deep learning. **Wood Science and Technology**, v.55, p.553-563, 2021.

XIONG, L.; ZHAO, H.; WANG, F.; CHENG, B. Genuine performance of China's forest products trade: An evaluation from the perspective of global value chains. **Forest Policy and Economics**, v. 144, 102823, 2022.

YANG, N.; BAI, Y.; JIANG, S.; YANG, C.; XU, K. Recognition method of plate and wood based on AlexNet optimization. **Scientia Silvae Sinicae**, v. 58, n. 3, p.149-158, 2022.

YANG, Y.; ZHOU, X.; LIU, Y.; HU, Z.; DING, F. Wood defect detection based on depth extreme learning machine. **Applied Sciences**, v. 10, n. 21, p. 7488, 2022.

YING, X. An overview of overfitting and its solutions. **Journal of physics: Conference series**, 1168, p. 022022, 2019.

YOSINSKI, J.; CLUNE, J.; BENGIO, Y.; LIPSON, H. How transferable are features in deep neural networks? **Conference: advances in neural information processing systems**, 2014.

YUSOF, R.; KHALID, M.; KHAIRUDDIN, A. S. M. Fuzzy data management on pores arrangement for tropical wood species recognition system. **Science and Information Conference**, London, UK, 2013, pp. 529-535.

ZHANG, C.; ZHOU, J. WANG, H.; TAN, T.; CUI, M.; HUANG, Z.; WANG, P.; ZHANG, L. Multi-species individual tree segmentation and identification based

on improved mask R-CNN and UAV imagery in mixed forests. **Remote Sensing**, v. 14, n. 4, p. 874, 2022.

ZHANG, P.; WANG, Z.; RAO, Y.; ZHENG, J.; ZHANG, N.; WANG, D.; ZHU, J.; FANG, Y.; GAO, X. Identification of pine wilt disease infected wood using UAV RGB imagery and improved YOLOv5 models integrated with attention mechanisms. **Forests**, v. 14, n. 3, p. 588, 2023.

ZHANG, X.; KE, S.; XU, T.; QIAO, D. Review of China's Forestry Industry over the Past 70 Years and an Outlook for the Future. **International Forestry Review**, v. 22, n. 2, p. 269-282, 2020.

ZHAO, G.; HUANG, X.; GIZATDINOVA, Y.; PIETIKÄINEN, M. Combining dynamic texture and structural features for speaker identification, in: **Proceedings of ACM Multimedia Workshop Multimedia in Forensics, Security and Intelligence**, p. 93-98., 2010.

ZHAO, H.; MORGENRHOT, J.; PEARSE, G.; SCHINDLER, J. A systematic review of individual tree crown detection and delineation with convolutional neural networks (CNN). **Current Forestry Reports**, v. 9, n. 3, p. 149-170, 2023.

ZHAO, Z. Q.; ZHENG, P.; XU, S.T.; WU, X. Object detection with deep learning: a review. **IEEE Transactions on Neural Network Learning Systems**, v. 30, n. 11, p. 3212-3232, 2019.

ZHAO, Z.; YANG, X.; GE, Z.; GUO, H.; ZHOU, Y. Wood microscopic image identification method based on convolution neural network. **BioResources**, v. 16, n. 3, 2021.


ZHENG, Y.; WANG, M.; ZHANG, B.; SHI, X.; CHANG, Q. GBCD-YOLO: A high-precision and real-time lightweight model for wood defect detection. **IEEE Access**, v. 12, p. 12853 - 12868, 2024.

ZHOU, S.; ZHU, H.; LIU, X.; HU, Q.; LU, H.; PENG, Z. Wood Surface Defect Detection Based on Improved YOLOv8s. **IAENG International Journal of Computer Science**, v. 51, n. 3, 2024.

ZHU, X.; SU, W.; LU, L.; LI, B.; WANG, X.; DAI, J.. Deformable DETR: Deformable transformers for end-to-end object detection. arXiv preprint arXiv:2010.04159, 2020.

ANEXO I


FIGURA 29 – IMAGENS MACROSCÓPICAS TRANSVERSAIS DAS 7 ESPÉCIES ESTUDADAS (DATASET CAATINGA)



FONTE: A autora (2024).

LEGENDA: A) *Aspidosperma pyriformium*; B) *Capparidastrium frondosum*; C) *Manihot baccata*; D) *Anadenanthera colubrina*; E) *Cenostigma pyramidale*; F) *Mimosa tenuiflora*; G) *Guapira* sp.

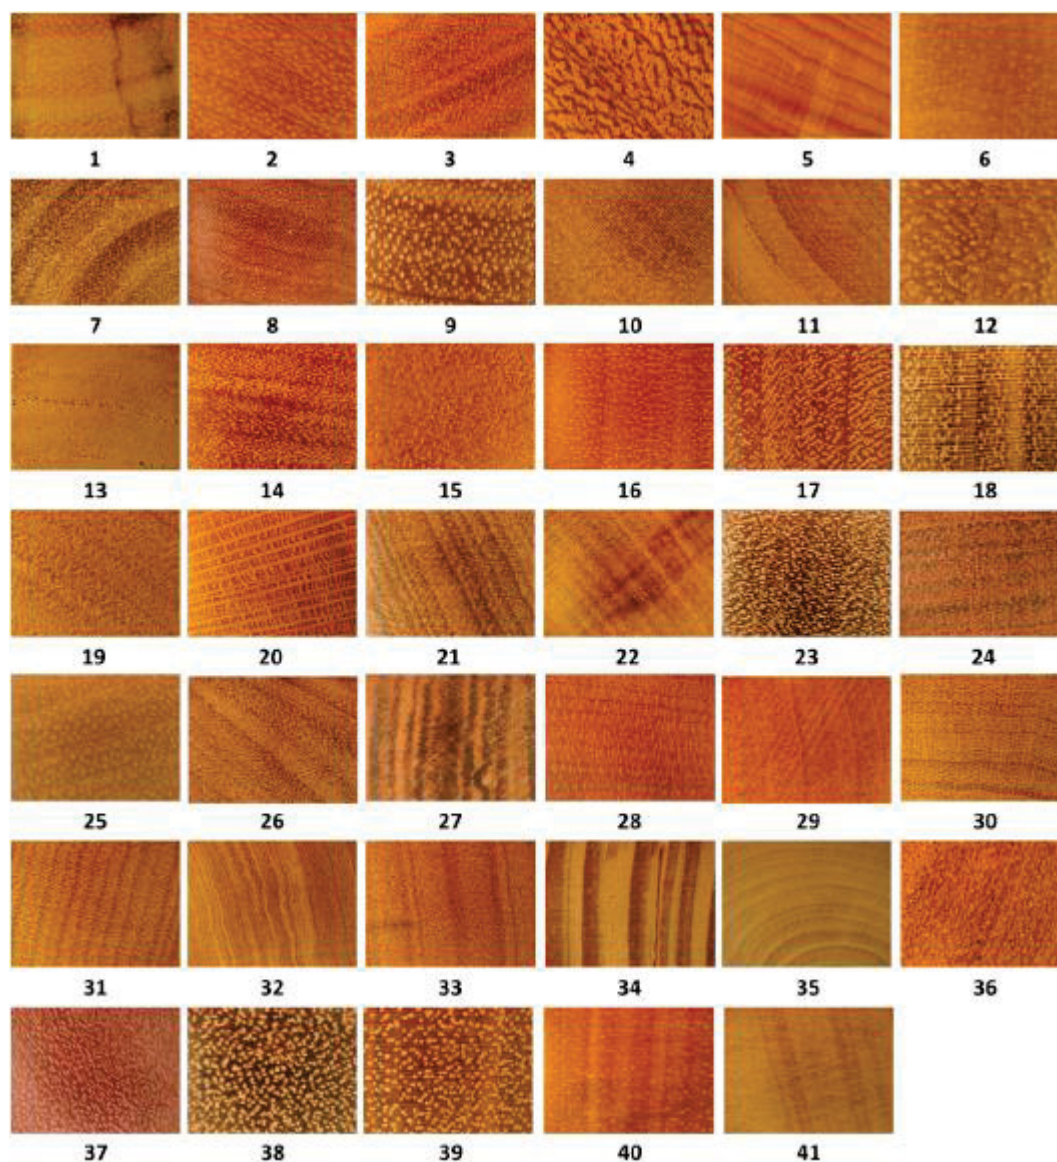
FIGURA 30 – IMAGENS MACROSCÓPICAS TRANSVERSAIS DAS 26 ESPÉCIES ESTUDADAS (DATASET MATA ATLÂNTICA)



FONTE: Andrade, Basso e Latorraca (2020).

Imagens macroscópicas de: A) *Amburana cearensis*; B) *Bowdichia virgilioides*; C) *Cordia trichotoma*; D) *Aspidosperma pyricollum*; E) *Handroanthus serratifolius*; F) *S. polyphylla*; G) *Tachigali vulgaris*; H) *Manilkara* sp.; I) *Paubrasilia echinata*; J) *Terminalia mameluco*; K) *Pterygota brasiliensis*; L) *Cariniana legalis*; M) *Copaifera lucens*; N) *Barnebydendron riedelii*; O) *Lecythis pisonis*; P) *Dalbergia nigra*; Q) *Astronium concinnum*; R) *Astronium graveolens*; S) *Anadenanthera peregrina*; T) *Parapiptadenia pterosperma*; U) *Plathymenia foliolosa*. Imagens macroscópicas com baixa qualidade e/ou ruído de: V) *Astronium concinnum*; X) *Astronium graveolens*; Z) *Paubrasilia echinata*; W) *Copaifera lucens*.

FIGURA 31 – IMAGENS MACROSCÓPICAS TRANSVERSAIS DAS 41 ESPÉCIES ESTUDADAS (FOREST SPECIES DATABASE - MACROSCOPIC)



FONTE: Paula Filho et al. (2014).

1) *Acrocarpus fraxinifolius*; 2) *Brosimum paraense* (*Brosimum rubescens* Taub.); 3) *Carapa guianensis*; 4) *Hymenolobium petraeum*; 5) *Araucaria angustifolia*; 6) *Hura crepitans*; 7) *Mimosa scabrella*; 8) *Myroxylon balsamum*; 9) *Bertholletia excelsa*; 10) *Erisma uncinatum*; 11) *Cedrela fissilis*; 12) *Cedrelinga cateniformis*; 13) *Melia azedarach*; 14) *Dipteryx* sp.; 15) *Goupia glabra*; 16) *Micropholis venulosa*; 17) *Eucalyptus* sp.; 18) *Cordia goeldiana*; 19) *Pouteria pachycarpa*; 20) *Grevillea robusta*; 21) *Ocotea porosa*; 22) *Tabebuia* sp.; 23) *Mezilaurus itauba*; 24) *Hymenaea* sp.; 25) *Cariniana estrellensis*; 26) *Machaerium* sp.; 27) *Laurus nobilis*; 28) *Manilkara elata*; 29) *Swietenia macrophylla*; 30) *Cordia* sp.; 31) *Euxylophora paraenses*; 32) *Balfourodendron riedelianum*; 33) *Aspidosperma polyneuron*; 34) *Pinus* sp.; 35) *Podocarpus lambertii*; 36) *Vochysia* sp.; 37) *Peltogyne* sp.; 38) *Bowdichia* sp.; 39) *Bagassa guianensis*; 40) *Couratari* sp.; 41) *Virola surinamensis*..

FIGURA 32 – IMAGENS MACROSCÓPICAS TRANSVERSAIS DAS 46 ESPÉCIES ESTUDADAS (BANCO DE DADOS *ENDANGERED FOREST SPECIES*)



FONTE: Souza et al. (2020)

LEGENDA: 1) *Acrocarpus fraxinifolius*; 2) *Araucaria angustifolia*; 3) *Aspidosperma polyneuron*; 4) *Aspidosperma* sp.; 5) *Bagassa guianensis*; 6) *Balfourodendron riedelianum*; 7) *Bertholletia excelsa*; 8) *Bowdichia* sp.; 9) *Brosimum parinarioides*; 10) *Carapa guianensis*; 11) *Cariniana estrellensis*; 12) *Cedrela fissilis*; 13) *Cedrelinga cateniformis*; 14) *Cordia goeldiana*; 15) *Couratari* sp.; 16) *Dipteryx* sp.; 17) *Erisma uncinatum*; 18) *Eucalyptus* sp.; 19) *Eugenia pyriformis*; 20) *Euxylophora paraenses*; 21) *Goupia glabra*; 22) *Grevillea robusta*; 23) *Handroanthus* sp.; 24) *Hymenaea* sp.; 25) *Hymenolobium petraeum*; 26) *Hymenolobium* sp.; 27) *Inga vera*; 28) *Laurus nobilis*; 29) *Machaerium paraguariense*; 30) *Machaerium* sp.; 31) *Manilkara elata*; 32) *Melia azedarach*; 33) *Mezilaurus itauba*; 34) *Micropholis venulosa*; 35) *Mimosa scabrella*; 36) *Muelleria paraenses*; 37) *Myroxylon balsamum*; 38) *Nectandra megapotamica*; 39) *Ocotea indecora*; 40) *Ocotea porosa*; 41) *Peltogyne* sp.; 42) *Pinus* sp.; 43) *Pouteria pachycarpa*; 44) *Simarouba amara*; 45) *Swietenia macrophylla*; 46) *Vochysia* sp.