



Serviço Público Federal
Universidade Federal do Pará
Campus Universitário de Altamira

PPGBC
PROGRAMA DE PÓS-GRADUAÇÃO EM
BIODIVERSIDADE E CONSERVAÇÃO

PROGRAMA DE PÓS-GRADUAÇÃO EM BIODIVERSIDADE E CONSERVAÇÃO

Natally Celestino Gama

**RECONHECIMENTO AUTOMÁTICO DE ESPÉCIES FLORESTAIS
AMAZÔNICAS A PARTIR DE IMAGENS DE CASCAS BASEADO EM
PADRÕES BINÁRIOS LOCAIS E APRENDIZADO PROFUNDO**

Orientador: Prof. Dr. Deivison Venicio Souza
Coorientadores: Prof. Dr. Samuel de P. C. Carvalho
Prof. Dr. Luiz Eduardo S. Oliveira

ALTAMIRA - PA
MAIO – 2024

UNIVERSIDADE FEDERAL DO PARÁ
CAMPUS ALTAMIRA
PROGRAMA DE PÓS-GRADUAÇÃO EM BIODIVERSIDADE E CONSERVAÇÃO

Natally Celestino Gama

**RECONHECIMENTO AUTOMÁTICO DE ESPÉCIES FLORESTAIS
AMAZÔNICAS A PARTIR DE IMAGENS DE CASCAS BASEADO EM
PADRÕES BINÁRIOS LOCAIS E APRENDIZADO PROFUNDO**

Orientador: Prof. Dr. Deivison Venicio Souza
Coorientadores: Prof. Dr. Samuel de P. C. Carvalho
Prof. Dr. Luiz Eduardo S. Oliveira

Dissertação de mestrado apresentada à Universidade Federal do Pará, como parte das exigências do Programa de Pós-graduação em Biodiversidade e Conservação (PPGBC) para obtenção de título de Mestre em Biodiversidade e Conservação.

ALTAMIRA - PA
MAIO – 2024

FICHA CATALOGRÁFICA

**Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)**

G184r Gama, Natally Celestino.

Reconhecimento automático de espécies florestais amazônicas a partir de imagens de cascas baseado em padrões binários locais e aprendizado profundo / Natally Celestino Gama. — 2024.

89 f. : il. color.

Orientador(a): Prof. Dr. Deivison Venicio Souza

Coorientador(a): Prof. Dr. Samuel de Pádua Chaves E Carvalho

Dissertação (Mestrado) - Universidade Federal do Pará,
Campus Universitário de Altamira, Programa de Pós-Graduação
em Biodiversidade e Conservação, Altamira, 2024.

1. Manejo florestal. 2. censo florestal. 3. identificação de espécies. 4. inteligência artificial. 5. aprendizado por transferência.

I. Título.

CDD 577.3

NATALLY CELESTINO GAMA

**RECONHECIMENTO AUTOMÁTICO DE ESPÉCIES FLORESTAIS
AMAZÔNICAS A PARTIR DE IMAGENS DE CASCAS BASEADO EM
PADRÕES BINÁRIOS LOCAIS E APRENDIZADO PROFUNDO**

Dissertação de mestrado apresentada à
Universidade Federal do Pará, como parte
das exigências do Programa de Pós-
graduação em Biodiversidade e
Conservação (PPGBC) para obtenção de
título de Mestre em Biodiversidade e
Conservação.

Data da aprovação: 28/05/2024

Banca examinadora:

Documento assinado digitalmente



PEDRO LUIZ DE PAULA FILHO

Data: 03/06/2024 12:43:34-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. Pedro Luiz de Paula Filho

Examinador externo - UTFPR

Documento assinado digitalmente



EDUARDO DA SILVA LEAL

Data: 03/06/2024 15:32:25-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. Eduardo da Silva Leal

Examinador externo - UFRA

Documento assinado digitalmente



EVANDRO FERREIRA DA SILVA

Data: 03/06/2024 16:04:51-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. Evandro Ferreira da Silva

Examinador interno - UFPA

ALTAMIRA - PA
MAIO – 2024

Agradecimentos

Agradeço primeiramente a Deus pela sua graça e amor sobre mim, pela vida, saúde, pela família e amigos que Ele me deu, e pela oportunidade de estar alcançando mais uma conquista na minha vida profissional.

Ao CIPEM pelos recursos fornecidos, e por financiar este projeto tão importante no contexto florestal. Agradeço a bolsa disponibilizada, pois sem isto, seria praticamente impossível permanecer neste mestrado.

À Universidade Federal do Pará (UFPA) – Campus de Altamira e ao Programa de Pós-graduação em Biodiversidade e Conservação (PPGBC), com todo seu corpo docente pelo conhecimento transmitido, fundamental para o desenvolvimento dessa pesquisa.

Ao meu orientador Deivison Venício, por toda paciência que teve comigo durante este período, pelo conhecimento transmitido, dentro e fora da sala de aula, pelo cuidado e atenção e por estar sempre disponível nos momentos necessários. Obrigada por ter confiado em mim para a realização desta pesquisa, saiba que me sinto honrada e feliz, por fazer parte deste projeto e por alcançar níveis de conhecimento que eu jamais imaginei que seria capaz. Agradeço por me incentivar quando eu mais precisei, pela preocupação com minha saúde e bem-estar, e sobretudo, pela amizade. Muito obrigada!

Aos meus coorientadores, Samuel Carvalho e Luiz Oliveira, pelo conhecimento compartilhado, pela disponibilidade em contribuir em todas as etapas da pesquisa e por me ajudarem sempre que necessário.

Ao Laboratório de Manejo Florestal, Tecnologias e Comunidades Amazônicas (LMFTCA), coordenado pelo professor Deivison, e aos seus integrantes.

Agradeço ao meu parceiro de laboratório Arandi Diego, pela companhia, pelas conversas, pelos momentos de café e comemoração, pelas risadas e amizade.

As minhas amigas dos Laboratórios de Socioeconomia e Geoma, Sayara, Fernanda e Thais pela amizade e carinho. Agradeço a companhia todos os dias, pelos momentos de conversas e risadas, e por todo apoio neste período.

Aos meus pais Antonia e Gildasio, por todo apoio e amor, por serem o meu suporte quando eu preciso. Por me incentivarem a avançar em cada etapa da minha vida e conquistar meus objetivos. Amo vocês! Agradeço a minha irmã Priscila, pelo incentivo a avançar na minha vida profissional, pela preocupação e carinho.

A minha prima Lidiane, por ser alguém com quem eu posso compartilhar todos os meus sonhos e planos, por que tenho certeza de que ela vai me incentivar a realizar. Obrigada pelo amor, carinho e amizade.

A minha amiga Juliana pela amizade, orações, pelos momentos de conversa e por todo carinho. Saiba que você fez a diferença na minha vida amiga.

As minhas amigas Arianne e Virgínia, pelas orações, amizade e apoio em todos os momentos. E aos meus amigos Wemerson Shimon e Tárta Zaluth, pela amizade e por me incentivarem a entrar neste mestrado. Agradeço todo o apoio!

Gratidão a todos vocês!

Sumário

1. INTRODUÇÃO GERAL	1
2. OBJETIVOS.....	3
2.1. Objetivo geral.....	3
2.2. Objetivos específicos.....	3
3. REFERÊNCIAS BIBLIOGRÁFICAS	4
INTELIGÊNCIA ARTIFICIAL E VISÃO COMPUTACIONAL NO RECONHECIMENTO AUTOMÁTICO DE PLANTAS: UMA ANÁLISE CIENCIOMÉTRICA	7
1. INTRODUÇÃO	10
2. MATERIAL E MÉTODOS.....	12
2.1. Coleta de dados	12
2.2. Análise de dados.....	12
3. RESULTADOS.....	13
3.1. Base de dados	13
3.2. Análise dos manuscritos.....	15
3.3. Descritores de recursos e classificadores	17
4. DISCUSSÃO	20
4.1. Base de dados	20
4.2. Análise dos manuscritos.....	20
4.2.1. Estruturas Botânicas	20
4.2.2. Tipos de formas de vida e origem dos bancos de dados	22
4.2.3. Tipos de características extraídas das imagens de plantas	24
4.2.4. Descritores de características e classificadores	25
5. CONCLUSÕES	27
6. REFERÊNCIAS BIBLIOGRÁFICAS	28
RECONHECIMENTO DE ESPÉCIES DE ÁRVORES AMAZÔNICAS A PARTIR DE IMAGENS DE CASCA USANDO PADRÕES BINÁRIOS LOCAIS E APRENDIZADO POR TRANSFERÊNCIA	37
1. INTRODUÇÃO	40
2. MATERIAL E MÉTODOS.....	42
2.1. Áreas de estudo	42
2.2. Aquisição de imagens.....	43
2.3. Identificação de espécies e coleta de material botânico	46

2.4. Extração de subimagens (patches)	47
2.5. Extração de características das imagens originais e subimagens	48
2.5.1. Padrões Binários Locais (Local Binary Patterns – LBP)	49
2.5.2. Aprendizado por transferência (Transfer learning)	50
2.6. Algoritmos, validação cruzada e métricas de desempenho	51
2.6.1. Algoritmos de classificação	51
2.6.2. Divisão e imagens e validação cruzada	52
2.6.3. Métricas de desempenho	54
3. RESULTADOS.....	54
3.1. Caracterização do conjunto de imagens	54
3.2. Desempenho dos classificadores	55
4. DISCUSSÃO	62
4.1. Conjunto de imagens: características, fontes de variação e dificuldades.....	62
4.2. Padrões Binários Locais	63
4.3. Transferência de aprendizado.....	64
4.4. Classificações incorretas	66
5. CONCLUSÃO	68
6. REFERÊNCIAS BIBLIOGRÁFICAS	68
CONCLUSÃO GERAL	75
ANEXO 1	76

RESUMO GERAL

O objetivo principal da pesquisa foi desenvolver modelos de classificação, usando técnicas de inteligência artificial e visão computacional, para reconhecer 16 espécies de árvores exploradas comercialmente na Amazônia brasileira, no âmbito do Manejo Florestal Sustentável – MFS para fins madeireiros, baseado em imagens digitais de casca (ritidoma). No capítulo 1, foi realizada uma revisão cienciométrica da literatura para identificar e quantificar as pesquisas que empregaram inteligência artificial e visão computacional no reconhecimento automático de plantas. No total, foram contabilizadas 566 publicações, compreendendo o período de 1986 a 2023. Foi constatado um crescente número de publicações neste campo de domínio, com alta predominância do uso de técnicas de aprendizado profundo. No entanto, a maioria dos estudos estão concentrados no desenvolvimento de sistemas de reconhecimento baseados em imagens de folhas de plantas de pequeno porte, devido a facilidade de obtenção de imagens. Portanto, pesquisas com enfoque em outras estruturas da planta, como cascas, flores ou copa, ainda são incipientes, especialmente, quando envolvem árvores de grande porte, como as espécies florestais madeireiras da Amazônia brasileira. No capítulo 2, o objetivo foi desenvolver modelos de reconhecimento de espécies a partir das imagens de cascas de árvores de espécies de importância comercial no MFS para fins madeireiros. Para tanto, foram avaliadas duas estratégias de extração de características das imagens digitais das cascas das árvores: i) Padrões Binários Locais – PBL (do inglês, Local Binary Pattern - LBP); e ii) Redes Neurais Convolucionais (do inglês, Convolutional Neural Networks - CNN) pré-treinadas (ResNet50, VGG16, InceptionV3 e MobileNetV2). Essas características foram extraídas de imagens originais com alta resolução (3024 x 4032 e 4000 x 5328 pixels) capturadas por dois dispositivos e de subimagens de 256 x 256 pixels, extraídas aleatoriamente das imagens originais. Posteriormente, foram avaliados quatro algoritmos de aprendizado de máquina na construção de modelos de classificação: Máquinas de Vetores de Suporte (Support Vector Machine - SVM), Redes Neurais Artificiais (Artificial Neural Networks - ANN), Floresta Aleatória (Random Forest - RF) e Análise Discriminante Linear (Linear Discriminant Analysis - LDA). Em geral, as CNNs pré-treinadas extraíram padrões mais discriminativos para construção de modelos de classificação. O classificador construído usando ResNet50 como extrator de características de subimagens e o algoritmo SVM, apresentou maior acurácia (95%, $d = 1,07$), na validação cruzada. Este modelo pode ser utilizado com êxito na tarefa de reconhecimento de espécies florestais, usando como entrada imagens digitais das cascas de árvores das espécies-alvo deste estudo.

Palavras-chave: Manejo florestal, censo florestal, identificação de espécies, imagens de casca, inteligência artificial, aprendizado por transferência.

ABSTRACT

The main objective of the research was to develop classification models, using artificial intelligence and computer vision techniques, to recognize 16 species of trees commercially exploited in the Brazilian Amazon, within the scope of Sustainable Forest Management – MFS for timber purposes, based on digital images of bark (rhytidoma). In chapter 1, a scientometric review of the literature was carried out to identify and quantify research that used artificial intelligence and computer vision in automatic plant recognition. In total, 566 publications were recorded, covering the period from 1986 to 2023. An increasing number of publications in this domain field was noted, with a high predominance of the use of deep learning techniques. However, most studies are focused on the development of recognition systems based on images of small plant leaves, due to the ease of obtaining images. Therefore, research focusing on other plant structures, such as bark, flowers or crowns, is still in its infancy, especially when involving large trees, such as timber forest species from the Brazilian Amazon. In chapter 2, the objective was to develop species recognition models based on tree bark images of commercially important species in the MFS for timber purposes. To this end, two strategies for extracting features from digital images of tree bark were evaluated: i) Local Binary Patterns – PBL (Local Binary Pattern - LBP); and ii) pre-trained Convolutional Neural Networks (CNN) (ResNet50, VGG16, InceptionV3 and MobileNetV2). These features were extracted from high-resolution original images (3024 x 4032 and 4000 x 5328 pixels) captured by two devices and from sub-images of 256 x 256 pixels, randomly extracted from the original images. Subsequently, four machine learning algorithms were evaluated in the construction of classification models: Support Vector Machines (Support Vector Machine - SVM), Artificial Neural Networks (ANN), Random Forest (RF) and Linear Discriminant Analysis (LDA). In general, pre-trained CNNs extracted more discriminative patterns for building classification models. The classifier built using ResNet50 as a subimage feature extractor and the SVM algorithm showed greater accuracy (95%, $d = 1.07$) in cross-validation. This model can be successfully used in the task of recognizing forest species, using as input digital images of the tree bark of the target species of this study.

Keywords: Forest management, forest census, species identification, bark images, artificial intelligence, transfer learning.

1. INTRODUÇÃO GERAL

As plantas abrigam uma grande variabilidade de espécies e possuem um papel fundamental no fornecimento de recursos para a sociedade, abrangendo desde matéria-prima para a indústria até a regulação do clima (Velazco et al., 2022; Pironon et al., 2024). Portanto, é imperiosa a implementação de estratégias de conservação e uso sustentável desse recurso natural. Algumas das principais estratégias adotadas atualmente incluem a educação ambiental, a criação de áreas protegidas, o desenvolvimento de pesquisa e monitoramento, e adoção do manejo florestal sustentável (Miranda et al., 2020; Ramos et al., 2020; Marchi et al., 2022; Kok et al., 2023).

Nesse contexto, o sucesso de quaisquer estratégias de conservação e uso sustentável de recursos da flora, está condicionado a correta identificação de espécies por meio da sua nomenclatura científica, pois possibilita a criação de abordagens eficazes e direcionadas, admitindo as características inerentes a cada família, gênero ou espécie (Lacerda and Nimmo, 2010; Behroozian et al., 2024). As espécies da flora são, comumente, identificadas por meio de abordagens comparativas baseadas em estruturas como folhas, flores, frutos, sementes e cascas (Wäldchen and Mäder, 2018; Kanda et al., 2021; Faizal, 2022). Essas abordagens de identificação são fundamentais para viabilizar uma identificação acurada das plantas, facilitando as atividades de catalogação, estudo, utilização e conservação, em diferentes contextos.

Em contextos mais amplos, como nas indústrias médicas, farmacêuticas e alimentícias, isso implica em garantir a autenticidade e qualidade das matérias-primas vegetais, fator essencial para a segurança e eficácia dos produtos produzidos e destinados à população (Kaya et al., 2019; Işık and Özkan, 2021; Taslim et al., 2021). Em contextos mais específicos, como no âmbito do Manejo Florestal Sustentável – MFS para fins madeireiros, a correta identificação de espécies da flora permite a definição de estratégias de exploração sustentável de árvores de valor comercial, conciliado à conservação de espécies e a proteção daquelas ameaçadas de extinção, diminuindo os riscos de perdas ecológicas e econômicas (Procópio and Secco, 2008; Ferreira et al., 2020; Imaña Encinas et al., 2022).

A identificação de espécies não é uma tarefa de fácil execução, pois requer conhecimento especializado de profissionais, que identificam as espécies de árvores baseando-se em suas estruturas morfológicas, que muitas vezes apresentam alta similaridade entre espécies, tornando a atividade complexa, delongada e onerosa (Boston and Van Dijk, 2019; Ghosh and Roy, 2022). Além disso, há uma escassez de

profissionais, enquanto o número de espécies a serem identificadas é consideravelmente alto.

Estimativas sugerem que globalmente existem entre 200.000 e 420.000 espécies de angiospermas (Wäldchen and Mäder, 2018; Bisen, 2021; Taslim et al., 2021). O Brasil destaca-se no cenário mundial por possuir extensas áreas florestais nativas, estimando-se a existência de 46.975 espécies de plantas, algas e fungos, com cerca de 55% consideradas endêmicas e abrangendo aproximadamente 10% de todas as espécies da flora conhecidas pela ciência (BFG, 2021). Essas estimativas evidenciam a extensão da problemática enfrentada pelos profissionais na área de identificação botânica e abrem espaço para propostas de soluções capazes de acelerar a execução desta tarefa, diminuindo os erros.

Soluções tecnológicas baseadas em técnicas de visão computacional e aprendizagem de máquina têm sido abordadas nas literaturas como métodos eficientes no reconhecimento de plantas (Sachar and Kumar, 2021; Wang et al., 2023; Cui et al., 2023). Inicialmente, as técnicas empregadas consistiam em extrair características representativas de forma, cor ou textura, de imagens digitais de partes das plantas, como folhas ou flores (Šulc and Matas, 2017; Kumar et al., 2019; Ihsan et al., 2022). Posteriormente, essas características são usadas como vetores de entrada para o aprendizado de modelos de reconhecimento de espécies usando algoritmos de aprendizado de máquina, como Redes Neurais Artificiais - RNA (do inglês, Artificial Neural Networks – ANN) e Máquinas de Vetores de Suporte - MVS (do inglês, Support Vector Machine – SVM).

Recentemente, essa tarefa vem sendo realizada utilizando métodos de aprendizado profundo, como as Redes Neurais Convolucionais - RNC (do inglês, Convolutional Neural Networks – CNN), que extraem recursos de imagens e são capazes de aprender automaticamente as melhores representações dos dados (Cui et al., 2023). Desta forma, algumas pesquisas têm avançado na construção de modelos computacionais altamente acurados na tarefa de reconhecimento de diferentes espécies de plantas (Alsaedi et al., 2019; Remeš and Haindl, 2019; Wu et al., 2021).

Apesar dos avanços, o conhecimento sobre a aplicação de técnicas de visão computacional e aprendizagem de máquina no reconhecimento de plantas ainda apresenta algumas lacunas. Por exemplo, a generalização dos modelos para diferentes ambientes e condições ainda é um desafio, especialmente em ecossistemas complexos, como as florestas tropicais, onde a diversidade de espécies e as condições ambientais variadas podem afetar a precisão dos sistemas de reconhecimento. A adaptação dos modelos para esses ambientes requer considerações específicas, como a presença de vegetação densa,

mudanças na iluminação devido à cobertura florestal e a diversidade única de espécies vegetais.

Ademais, a escassez de conjuntos de dados rotulados e de alta qualidade ainda representa um desafio significativo no desenvolvimento e treinamento de modelos mais robustos. Portanto, uma análise abrangente do estado da arte na aplicação de inteligência artificial e visão computacional é crucial para superar essas lacunas e avançar na construção de sistemas de reconhecimento de plantas mais precisos e confiáveis.

Esta dissertação está dividida em dois capítulos em formato de artigos científicos, formatados em consonância às normas da revista escolhida para as publicações. No capítulo 1, foi realizada uma análise cientométrica sobre a aplicação de inteligência artificial e visão computacional no reconhecimento de plantas. No capítulo 2, foram avaliadas duas estratégias de extração de características das imagens digitais das cascas (ritidoma) das árvores: i) Padrões Binários Locais – PBL (do inglês, Local Binary Pattern - LBP); e ii) Redes Neurais Convolucionais (do inglês, Convolutional Neural Networks - CNNs) pré-treinadas (ResNet50, VGG16, InceptionV3 e MobileNetV2). Posteriormente, foram avaliados quatro algoritmos de aprendizado de máquina para aprendizado dos modelos de reconhecimento: Support Vector Machine (SVM), Artificial Neural Networks (ANN), Random Forest (RF) e Linear Discriminant Analysis (LDA).

2. OBJETIVOS

2.1. *Objetivo geral*

Desenvolver e avaliar modelos de reconhecimento de espécies florestais, usando diferentes técnicas de extração de características de imagens digitais de cascas (ritidoma) e algoritmos de aprendizado de máquina, visando a melhoria da acurácia na identificação de árvores no Manejo Florestal Sustentável para fins madeireiros.

2.2. *Objetivos específicos*

- Identificar e quantificar as principais tendências e lacunas sobre o reconhecimento automático de espécies de plantas, usando de técnicas de visão computacional e inteligência artificial, por meio da abordagem cientométrica;
- Avaliar o uso do algoritmo Local Binary Pattern - LBP como extrator de características de imagens digitais de casca (ritidoma) de árvores de espécies da Amazônia brasileira;

- Avaliar o uso de CNNs pré-treinadas (ResNet50, VGG16, InceptionV3 e MobileNetV2) como extratores de representações de imagens digitais de casca (ritidoma) de árvores de espécies da Amazônia brasileira;
- Avaliar o uso de quatro algoritmos de aprendizado de máquina (Support Vector Machine (SVM), Artificial Neural Networks (ANN), Random Forest (RF) e Linear Discriminant Analysis (LDA)) no aprendizado de modelos de reconhecimento de espécies, baseado em características extraídas de imagens digitais de casca (ritidoma) de árvores de espécies da Amazônia brasileira.

3. REFERÊNCIAS BIBLIOGRÁFICAS

- Alsaedi, N., Alahmadi, H., Syed, L., 2019. Desert Plants Recognition by Bark Texture, in: 2019 12th International Conference on Developments in ESystems Engineering (DeSE). IEEE, pp. 123–127. <https://doi.org/10.1109/DeSE.2019.00032>
- Behroozian, M., Pierce, S., Ejtehadi, H., Memariani, F., Rafiee, F., Joharchi, M.R., 2024. Relative contributions of taxonomic and functional diversity to the assembly of plant communities hosting endemic *Dianthus* species in a mountain steppe. *Sci. Rep.* 14, 5471. <https://doi.org/10.1038/s41598-024-56099-x>
- Bisen, D., 2021. Deep convolutional neural network based plant species recognition through features of leaf. *Multimed. Tools Appl.* 80, 6443–6456. <https://doi.org/10.1007/s11042-020-10038-w>
- Boston, T., Van Dijk, A., 2019. Some experiments in automated identification of Australian plants using convolutional neural networks, in: Proceedings of the 23rd International Congress on Modelling and Simulation (MODSIM2019). pp. 15–21.
- Cui, Z., Li, X., Li, T., Li, M., 2023. Improvement and Assessment of Convolutional Neural Network for Tree Species Identification Based on Bark Characteristics. *Forests* 14, 1292. <https://doi.org/10.3390/f14071292>
- Faizal, S., 2022. Automated Identification of Tree Species by Bark Texture Classification Using Convolutional Neural Networks. *Int. J. Res. Appl. Sci. Eng. Technol.* 10, 1384–1392. <https://doi.org/10.22214/ijraset.2022.46846>
- Ferreira, R.L.A., Cerqueira, R.M., Cardoso Junior, R.C., 2020. Análise da identificação botânica em inventários florestais de planos de manejo sustentáveis no oeste paraense. *Nat. Conserv.* 13, 136–145. <https://doi.org/10.6008/cbpc2318-2881.2020.003.0014>
- Ghosh, A., Roy, P., 2022. An automated model for leaf image-based plant recognition: an optimal feature-based machine learning approach. *Innov. Syst. Softw. Eng.* <https://doi.org/10.1007/s11334-022-00440-y>
- Ihsan, M.F., Sunyoto, A., Arief, M.R., 2022. Gray Level Co-Occurrence Matrix Algorithm and Backpropagation Neural Networks for Herbal Plants Identification, in: 2022 5th International Conference on Information and Communications Technology (ICOIACT). IEEE, pp. 373–378. <https://doi.org/10.1109/ICOIACT55506.2022.9972087>
- Imaña Encinas, J., Camargo Ferreira, M.A., Riesco Muñoz, G., Rojo Alboreca, A., 2022.

- Verificadores de sostenibilidad en inventarios forestales del bosque amazónico en el estado de Mato Grosso (Brasil). *Rev. Mex. Ciencias For.* 13, 30–54. <https://doi.org/10.29298/rmcf.v13i72.1179>
- Işık, Ş., Özkan, K., 2021. Overview of handcrafted features and deep learning models for leaf recognition. *J. Eng. Res.* 9. <https://doi.org/10.36909/jer.v9i1.7737>
- Kanda, P.S., Xia, K., Sanusi, O.H., 2021. A Deep Learning-Based Recognition Technique for Plant Leaf Classification. *IEEE Access* 9, 162590–162613. <https://doi.org/10.1109/ACCESS.2021.3131726>
- Kaya, A., Keceli, A.S., Catal, C., Yalic, H.Y., Temucin, H., Tekinerdogan, B., 2019. Analysis of transfer learning for deep neural network based plant classification models. *Comput. Electron. Agric.* 158, 20–29. <https://doi.org/10.1016/j.compag.2019.01.041>
- Kok, M.T.J., Meijer, J.R., van Zeist, W.-J., Hilbers, J.P., Immovilli, M., Janse, J.H., Stehfest, E., Bakkenes, M., Tabeau, A., Schipper, A.M., Alkemade, R., 2023. Assessing ambitious nature conservation strategies in a below 2-degree and food-secure world. *Biol. Conserv.* 284, 110068. <https://doi.org/10.1016/j.biocon.2023.110068>
- Kumar, M., Gupta, S., Gao, X.-Z., Singh, A., 2019. Plant Species Recognition Using Morphological Features and Adaptive Boosting Methodology. *IEEE Access* 7, 163912–163918. <https://doi.org/10.1109/ACCESS.2019.2952176>
- Lacerda, A.E.B. de, Nimmo, E.R., 2010. Can we really manage tropical forests without knowing the species within? Getting back to the basics of forest management through taxonomy. *For. Ecol. Manage.* 259, 995–1002. <https://doi.org/10.1016/j.foreco.2009.12.005>
- Marchi, C.M.D.F., Pimentel, P.C.B., Nascimento, M.C.P., 2022. Solid Waste in the Context of Environmental Education, the Mangrove Ecosystem, and Photography. *Ambient. Soc.* 25. <https://doi.org/10.1590/1809-4422asoc20210102r215ao>
- Miranda, K., Amaral Neto, M., Sousa, R., Coelho, R., 2020. Manejo Florestal Sustentável em Unidades de Conservação de uso comunitário na Amazônia. *Soc. Nat.* 32, 778–792. <https://doi.org/10.14393/SN-v32-2020-51621>
- Pironon, S., Ondo, I., Diazgranados, M., Allkin, R., Baquero, A.C., Cámara-Leret, R., Canteiro, C., Dennehy-Carr, Z., Govaerts, R., Hargreaves, S., Hudson, A.J., Lemmens, R., Milliken, W., Nesbitt, M., Patmore, K., Schmelzer, G., Turner, R.M., van Andel, T.R., Ulian, T., Antonelli, A., Willis, K.J., 2024. The global distribution of plants used by humans. *Science* (80-.). 383, 293–297. <https://doi.org/10.1126/science.adg8028>
- Procópio, L.C., Secco, R.D.S., 2008. A importância da identificação botânica nos inventários florestais: o exemplo do “tauari” (*Couratari* spp. e *Cariniana* spp. - *Lecythidaceae*) em duas áreas manejadas no estado do Pará. *Acta Amaz.* 38, 31–44. <https://doi.org/10.1590/S0044-59672008000100005>
- Ramos, W.F., Ruivo, M. de L.P., Sousa, L.M. de, Castro, R.M. da S., 2020. Environmental crimes against flora and deforestation in the municipality of Paragominas-PA, from 2010 to 2017. *Brazilian J. Dev.* 6, 66033–63048. <https://doi.org/10.34117/bjdv6n8-657>
- Remeš, V., Haindl, M., 2019. Bark recognition using novel rotationally invariant

- multispectral textural features. *Pattern Recognit. Lett.* 125, 612–617. <https://doi.org/10.1016/j.patrec.2019.06.027>
- Sachar, S., Kumar, A., 2021. Survey of feature extraction and classification techniques to identify plant through leaves. *Expert Syst. Appl.* 167, 114181. <https://doi.org/10.1016/j.eswa.2020.114181>
- Šulc, M., Matas, J., 2017. Fine-grained recognition of plants from images. *Plant Methods* 13, 115. <https://doi.org/10.1186/s13007-017-0265-4>
- Taslim, A., Saon, S., Mahamad, A.K., Muladi, M., Hidayat, W.N., 2021. Plant leaf identification system using convolutional neural network. *Bull. Electr. Eng. Informatics* 10, 3341–3352. <https://doi.org/10.11591/eei.v10i6.2332>
- The Brazil Flora Group, B., 2021. Flora do Brasil 2020. *Jard. Botânico do Rio Janeiro* <http://floradobrasil.jbrj.gov.br/Access> 19 Set 2. <https://doi.org/10.47871/jbrj2021001>
- Velazco, S.J.E., Bedrij, N.A., Rojas, J.L., Keller, H.A., Ribeiro, B.R., De Marco, P., 2022. Quantifying the role of protected areas for safeguarding the uses of biodiversity. *Biol. Conserv.* 268, 109525. <https://doi.org/10.1016/j.biocon.2022.109525>
- Wäldchen, J., Mäder, P., 2018. Plant Species Identification Using Computer Vision Techniques: A Systematic Literature Review. *Arch. Comput. Methods Eng.* 25, 507–543. <https://doi.org/10.1007/s11831-016-9206-z>
- Wang, Z., Cui, J., Zhu, Y., 2023. Review of plant leaf recognition. *Artif. Intell. Rev.* 56, 4217–4253. <https://doi.org/10.1007/s10462-022-10278-2>
- Wu, F., Gazo, R., Benes, B., Haviarova, E., 2021. Deep BarkID: a portable tree bark identification system by knowledge distillation. *Eur. J. For. Res.* 140, 1391–1399. <https://doi.org/10.1007/s10342-021-01407-7>

Este capítulo está formatado de acordo com as normas da revista Ecological Informatics, disponível em: <https://www.sciencedirect.com/journal/ecological-informatics/publish/guide-for-authors>

ARTIGO 1

INTELIGÊNCIA ARTIFICIAL E VISÃO COMPUTACIONAL NO RECONHECIMENTO AUTOMÁTICO DE PLANTAS: UMA ANÁLISE CIENCIOMÉTRICA

Inteligência artificial e visão computacional no reconhecimento automático de plantas: uma análise cienciométrica

Natally Celestino Gama^{a*}, Luiz Eduardo Soares Oliveira^b, Samuel de Pádua Chaves e Carvalho^c, Eduardo da Silva Leal^d, Joielan Xipaya dos Santos^e, Thais Santos Souza^f, Deivison Venicio Souza^g

^aUniversidade Federal do Pará – UFPA, Programa de Pós Graduação em Biodiversidade e Conservação, Rua Cel. José Porfírio, 2515 - Centro, CEP: 68372040, Altamira, PA, Brazil, email: natallygama28@gmail.com.

^bUniversidade Federal do Paraná - UFPR, Departamento de Informática, Rua Cel. Francisco Heráclito dos Santos, 100 - Jardim das Américas CEP: 81531990, Curitiba, PR, Brazil, email: lesoliveira@gmail.com.

^cUniversidade Federal Rural do Rio de Janeiro - UFRRJ, Instituto Florestal. BR-465 - Km 7, CEP: 23897000, Seropédica, RJ, Brasil, email: samuel.carvalho@ufrj.br.

^dUniversidade Federal Rural da Amazônia - UFRA, Campus Capanema, Avenida Barão de Capanema, s/n – CEP: 68700-665, Capanema, PA, Brazil, email: eduardo.leal@ufra.edu.br.

^eUniversidade Federal do Paraná - UFPR, Departamento de Engenharia Florestal e Tecnologia, Avenida Prefeito Lothário Meissner - Jardim Botânico, CEP: 80210-170, Curitiba, PR, Brasil, email: joilan87xipaya@gmail.com.

^fUniversidade Federal do Pará – UFPA, Programa de Pós Graduação em Biodiversidade e Conservação, Rua Cel. José Porfírio, 2515 - Centro, CEP: 68372040, Altamira, PA, Brazil, email: souzathais1211@gmail.com.

^gUniversidade Federal do Pará – UFPA, Faculdade de Engenharia Florestal, Rua Cel. José Porfírio, 2515 - Centro, CEP: 68372040, Altamira, PA, Brazil, email: deivisonvs@ufpa.br.

*Autor correspondente: e-mail: natallygama28@gmail.com

RESUMO

A identificação botânica é uma atividade importante para auxiliar na conservação da biodiversidade e garantir a preservação de plantas ameaçadas, sendo uma tarefa desafiadora para profissionais da área da botânica devido as similaridades presentes em suas estruturas. Soluções tecnológicas, baseadas em visão computacional e inteligência artificial, têm sido apresentadas na literatura como alternativa para acelerar os processos de reconhecimento sem comprometer a acurácia. Desta forma, é necessária uma análise ampla sobre esta temática, a fim de apontar as lacunas existentes e verificar quais as tendências para as pesquisas. O presente estudo teve como objetivo, realizar uma revisão sistemática da literatura para verificar o panorama atual sobre o emprego de técnicas de visão computacional e aprendizado de máquina para o reconhecimento de plantas. A pesquisa foi realizada nas plataformas Scopus e Web of Science utilizando termos técnicos comuns relacionados ao tema. A busca retornou um total de 1.659 artigos publicados, dos quais 566 estavam dentro dos critérios previamente estabelecidos para a pesquisa. Na maioria das pesquisas são utilizadas imagens de folhas das plantas provenientes principalmente de árvores de pequeno a médio porte ou plantas herbáceas, o que abre espaço para o desenvolvimento de estudos utilizando imagens de outras estruturas botânicas como flores ou cascas, que sejam também oriundas de plantas com dimensões maiores como as espécies florestais amazônicas. As abordagens tradicionais, que utilizam algoritmos para a extração de características das imagens combinadas com algoritmos de aprendizado de máquina, têm mostrado bom desempenho estatístico. Porém, o aprendizado profundo por meio das Redes Neurais Convolucionais tem se mostrado a principal linha de investigação dos pesquisadores nos últimos anos, uma vez que, permite o desenvolvimento de modelos computacionais de reconhecimento de plantas abrangendo todas as etapas de construção do modelo, e utilizando diversas estruturas botânicas.

Palavras-chaves: reconhecimento de plantas, aprendizado de máquina, visão computacional, processamento de imagens.

1. INTRODUÇÃO

As plantas exercem uma função vital tanto para a sociedade quanto para o meio ambiente, fornecendo uma variedade de benefícios que incluem alimentos, refúgio e recursos para a indústria. Além disso, desempenham um papel crucial na manutenção do equilíbrio ambiental, regulando a temperatura e contribuindo para a purificação do ar (Ahmed; Hussein, 2020; Ali; Fahad, 2022). Considerando esses benefícios, são necessárias práticas para conservar as espécies da flora e protegê-las de fatores como o desmatamento, urbanização e a superexploração, que levam a extinção dessas espécies (Ariyapadath, 2021).

Para propor práticas de conservação é necessário conhecer as espécies da flora, e neste sentido, a identificação botânica se configura como uma atividade que auxilia na conservação da biodiversidade, garantindo a preservação de plantas ameaçadas e facilitando as ações de monitoramento ecológico (Atique et al., 2022; Figueroa-Mata et al., 2022). Esta atividade é comumente realizada por profissionais botânicos e/ou taxonomistas, que realizam o reconhecimento das espécies, analisando as semelhanças presentes em suas estruturas morfológicas como folhas, flores, frutos e cascas (Aqib Haqmi Abas et al., 2018; Amlekar; Gaikwad, 2019; Arafat; Arshad; Khan, 2021).

No entanto, essas estruturas muitas vezes podem possuir diversas similaridades, gerando erros na identificação das espécies, comprometendo a acurácia e transformando o reconhecimento de plantas em uma tarefa desafiadora para o identificador (Bisen, 2021; Atique et al., 2022; Athapaththu; Piumi Ishanka, 2023). Além disso, a grande diversidade de espécies e a escassez de especialistas botânicos, aliada ao tempo exigido pelos métodos tradicionais de identificação, resultam em tarefas de reconhecimento que são dispendiosas (Bouchahma et al., 2019; Chompookham et al., 2020; Chavan et al., 2021).

Neste sentido, soluções tecnológicas que visem automatizar as atividades de identificação, são úteis para acelerar os processos de reconhecimento sem comprometer a acurácia (Sachar; Kumar, 2021; Ghosh; Singh; Kumar, 2023; Wang; Cui; Zhu, 2023). Essas soluções vêm sendo abordadas em diversos estudos, que empregaram técnicas de visão computacional e aprendizado de máquina para o reconhecimento de plantas (Gulac; Bayazit, 2018; Hidayat; Ramadona Nilawati, 2018; Ghosh; Roy, 2022; Ihsan; Sunyoto; Arief, 2022). Nesses estudos, o reconhecimento de espécies vegetais é abordado como uma tarefa de classificação, em que imagens de estruturas botânicas são utilizadas como entrada para os algoritmos de aprendizado de máquina.

As imagens geralmente são compostas por centenas de pixels com informações numéricas associadas a cores, sendo necessário reduzi-las a vetores que contenham apenas elementos relevantes para o problema de classificação (Wäldchen et al., 2018). Para a formação desses vetores, diversas pesquisas se concentraram no desenvolvimento de algoritmos de visão computacional, para extrair características como por exemplo: cor, textura e forma de imagens das estruturas botânicas das plantas (Harjanti; Madenda, 2019; Hazra; Bhattacharyya; Kim, 2021; Işık; Özkan, 2021). Essas características são convertidas em vetores numéricos e utilizadas como entrada para algoritmos de classificação como as Redes Neurais Artificiais (Artificial Neural Networks - ANN), Máquinas de Vetores de Suporte (Support Vector Machine - SVM) e K-Vizinho mais Próximo (K-Nearest Neighbor - KNN), configurando as chamadas abordagens tradicionais.

Além da utilização dessas abordagens, recentemente, o avanço em técnicas de aprendizado profundo (Deep Learning), como as Redes Neurais Convolucionais (Convolutional Neural Networks - CNN), tem se destacado nos estudos de reconhecimento de plantas (Carpentier; Giguere; Gaudreault, 2018; Dileep; Pournami, 2019; Chung; Chou; Li, 2021; Cui et al., 2023). Diferentemente das abordagens tradicionais, as CNNs realizam todo o processo desde a extração de características, descobrindo estatisticamente a melhor representação das imagens, até a classificação das espécies, o que demanda o emprego de bases de dados maiores e aumenta o esforço computacional (Wäldchen et al., 2018).

A utilização de abordagens tradicionais e de técnicas de aprendizado profundo nos estudos de reconhecimento de plantas, são geralmente, relatadas em artigos de revisão apenas compreendendo um período ou característica botânica específica. Wäldchen e Mäder (2018) analisaram os artigos publicados no período de 2005 a 2010, descrevendo os principais métodos aplicados, e as estruturas botânicas mais utilizadas, comparando as acurácias alcançadas por cada um. Thyagarajan e Kiruba Raji (2019) revisaram os trabalhos que empregaram vários métodos de classificação utilizando imagens apenas de folhas de plantas.

Desta forma, fica evidente que, considerando as contribuições que estas pesquisas concedem aos processos de reconhecimento de plantas e, por consequência, auxiliar na sua conservação, ainda é necessária uma análise mais ampla sobre esses estudos, a fim de apontar as lacunas existentes e verificar quais as tendências para as pesquisas, o que é fundamental para guiar futuros trabalhos sobre o tema. Neste sentido, o presente estudo

teve como objetivo, realizar uma revisão sistemática da literatura para verificar o panorama atual sobre o emprego de técnicas de visão computacional e aprendizado de máquina para o reconhecimento de plantas.

Para isso, foram formuladas as seguintes questões de pesquisa: (i) Há alguma tendência prevista para os futuros artigos publicados, baseados nos estudos atuais?; (ii) Quais as estruturas botânicas das plantas que estão sendo mais utilizadas nas pesquisas?; (iii) Quais os tipos de formas de vida estão sendo mais citados nos estudos? (iv) Quais as técnicas de extração de características das imagens que estão sendo mais empregadas?; (v) Quais as principais técnicas de classificação usadas para desenvolver os modelos de reconhecimento e quais tem mostrado melhor performance estatística?

2. MATERIAL E MÉTODOS

2.1. Coleta de dados

Para a obtenção dos dados, inicialmente foi realizada uma pesquisa exploratória utilizando o Google Acadêmico, que é uma plataforma que abrange diversos tipos de trabalhos científicos. Nesta plataforma foram verificados os termos técnicos empregados em artigos sobre reconhecimento de plantas a partir de abordagens de visão computacional e aprendizado de máquina.

Os termos técnicos resultantes desta pesquisa inicial foram utilizados para realizar um levantamento bibliográfico nas bases de dados Web of Science e Scopus. A busca foi realizada no dia 12 de agosto de 2023, empregando as seguintes palavras-chaves: ("wood recognition") OR ("flower recognition") OR ("bark recognition") OR ("leaf recognition") OR ("plant recognition") OR ("plant identification") OR ("plant classification") OR ("Tree species identification") AND ("deep learning") OR ("machine learning") OR ("computer vision") OR ("feature extraction") OR ("image processing") OR ("Pattern recognition").

2.2. Análise de dados

A pesquisa foi limitada a apenas artigos de periódicos de caráter experimental ou de conferências publicados em língua inglesa, sendo avaliados através da leitura de título, resumo, objetivos e, quando necessário, através da leitura completa do artigo. A inclusão de artigos de conferência se deve ao fato de a temática da pesquisa ser totalmente voltada para a área da computação (ou ciências afins), em que a maioria dos autores tem a

tendência de participar, por possuir maior visibilidade tanto do meio acadêmico quanto da indústria.

Para cada artigo analisado foram registradas as seguintes informações: 1) ano de publicação; 2) estruturas botânicas utilizadas para reconhecimento de plantas; 3) características extraídas (forma, textura, cor, representações); 4) descritores de características utilizados; 5) técnicas de classificação; 6) acurácia dos classificadores; 7) formas de vida e categorias de plantas (árvores, arbustos, plantas herbáceas, plantas medicinais); e 8) países de origem dos bancos de dados.

As análises foram realizadas no Excel 365® e no R em sua versão 4.3.1 utilizando a biblioteca *biblioshiny* para os processos de fusão dos dados provenientes das duas bases (WoS e Scopus), e exclusão de possíveis artigos duplicados.

3. RESULTADOS

3.1. Base de dados

A busca realizada nas bases de dados retornou um total de 1.659 artigos publicados por pesquisadores de diferentes nacionalidades nos últimos 37 anos (1986 – 2023), sendo que desses, 566 artigos (em que 240 são artigos de periódicos e 326 são de conferências), estavam dentro dos critérios estabelecidos para a pesquisa. No período de 1986 a 2008 (22 anos) houve apenas 16 publicações sobre reconhecimento de plantas utilizando técnicas de visão computacional e aprendizado de máquina, estando muitas vezes limitado a apenas uma publicação no ano, e com intervalos de anos em que não houve publicações. A partir de 2009 o número de manuscritos publicados cresceu, sendo o ano de 2022 o que teve o maior número de publicações (97 artigos) (Figura 1).




Figura 1: Número de artigos que fizeram pesquisa sobre o reconhecimento de plantas utilizando técnicas de visão computacional e aprendizado de máquina entre os anos de 1986 e 2023.

A Índia e a China são os países que mais publicaram artigos sobre esta temática, com 121 e 120 artigos publicados, respectivamente. Em seguida tem-se a Malásia (39), França (24), Turquia (22), Indonésia (21), Brasil (19) e Estados Unidos (16) (Figura 2). O número de artigos publicados nos demais países ficou abaixo de 15.

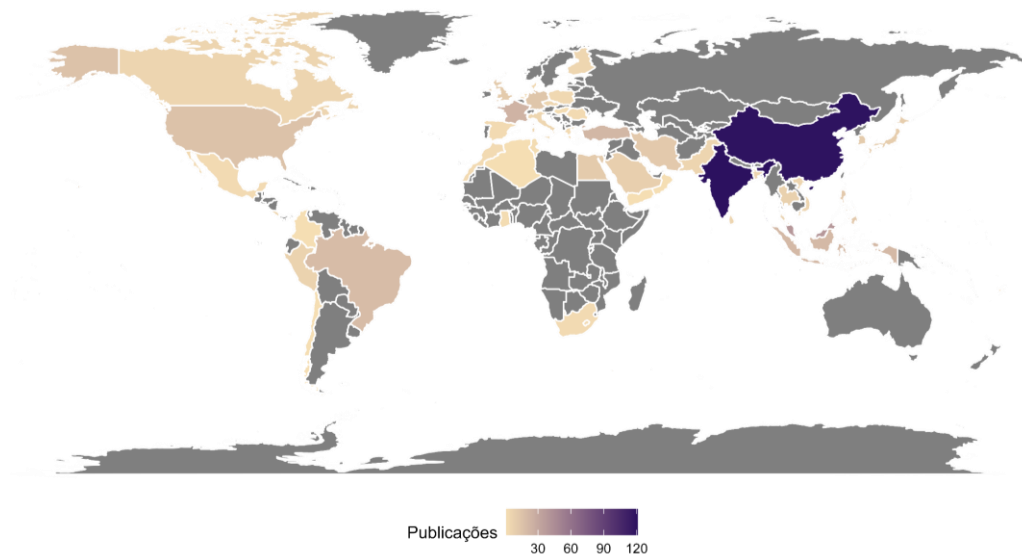


Figura 2: Número de artigos publicados por países entre os anos de 1986 e 2023.

Os 566 artigos foram publicados em 348 periódicos diferentes, sendo o *CEUR Workshop Proceedings* e o *Lecture Notes in Computer Science* os que possuem o maior número de publicações, com 29 e 20 manuscritos publicados, respectivamente. Logo em

seguida tem-se o *Communications in Computer and Information Science* com 14 artigos, *Computers and Electronics in Agriculture* e *IEEE ACCESS* ambos com 12, e o *Advances in Intelligent Systems and Computing* com 11 artigos publicados (Figura 3). Os demais periódicos possuíam menos de 10 publicações.

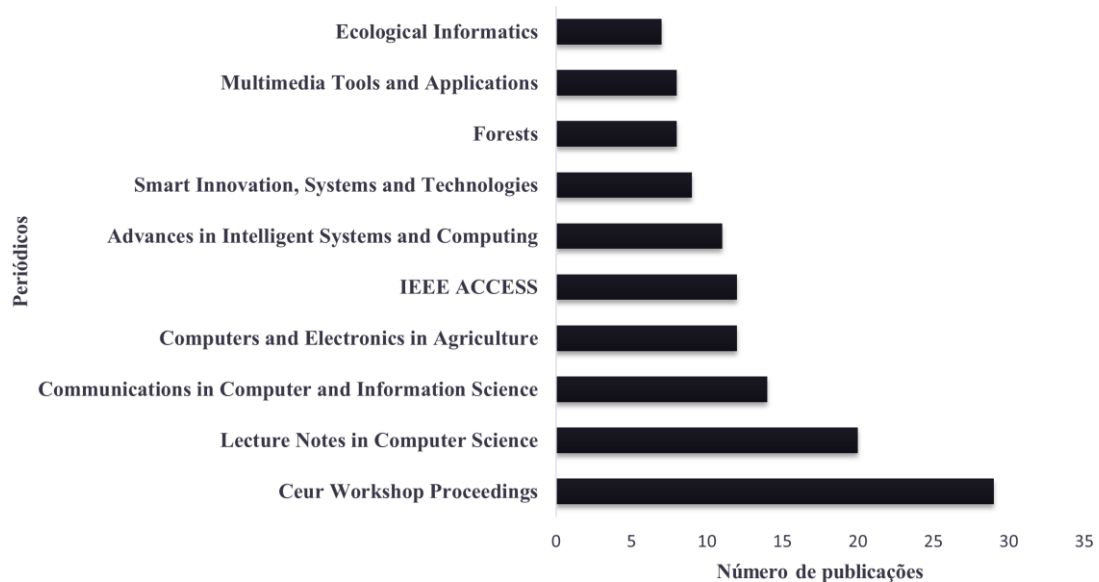


Figura 3: Os 10 principais periódicos que publicaram artigos sobre o reconhecimento de plantas por abordagens de visão computacional e aprendizado de máquina entre os anos de 1986 e 2023.

3.2. *Análise dos manuscritos*

Os pesquisadores utilizaram diferentes estruturas botânicas para a construção de modelos de reconhecimento de plantas, com predominância do uso de imagens de folhas (63,78%), seguido por imagens de flores (8,66%) e, a utilização de bancos de dados de imagens compostas por múltiplos órgãos da planta, tais como folhas, flores e casca (8,48%) (Figura 4A). Já com relação aos tipos formas de vida que compõem os conjuntos de dados, a maioria dos pesquisadores emprega o uso de estruturas botânicas provenientes de árvores (31,45%) ou de vários tipos de formas de vida – arbóreas, herbáceas ou plantas inteiras – ao mesmo tempo (30,92%) (Figura 4B).

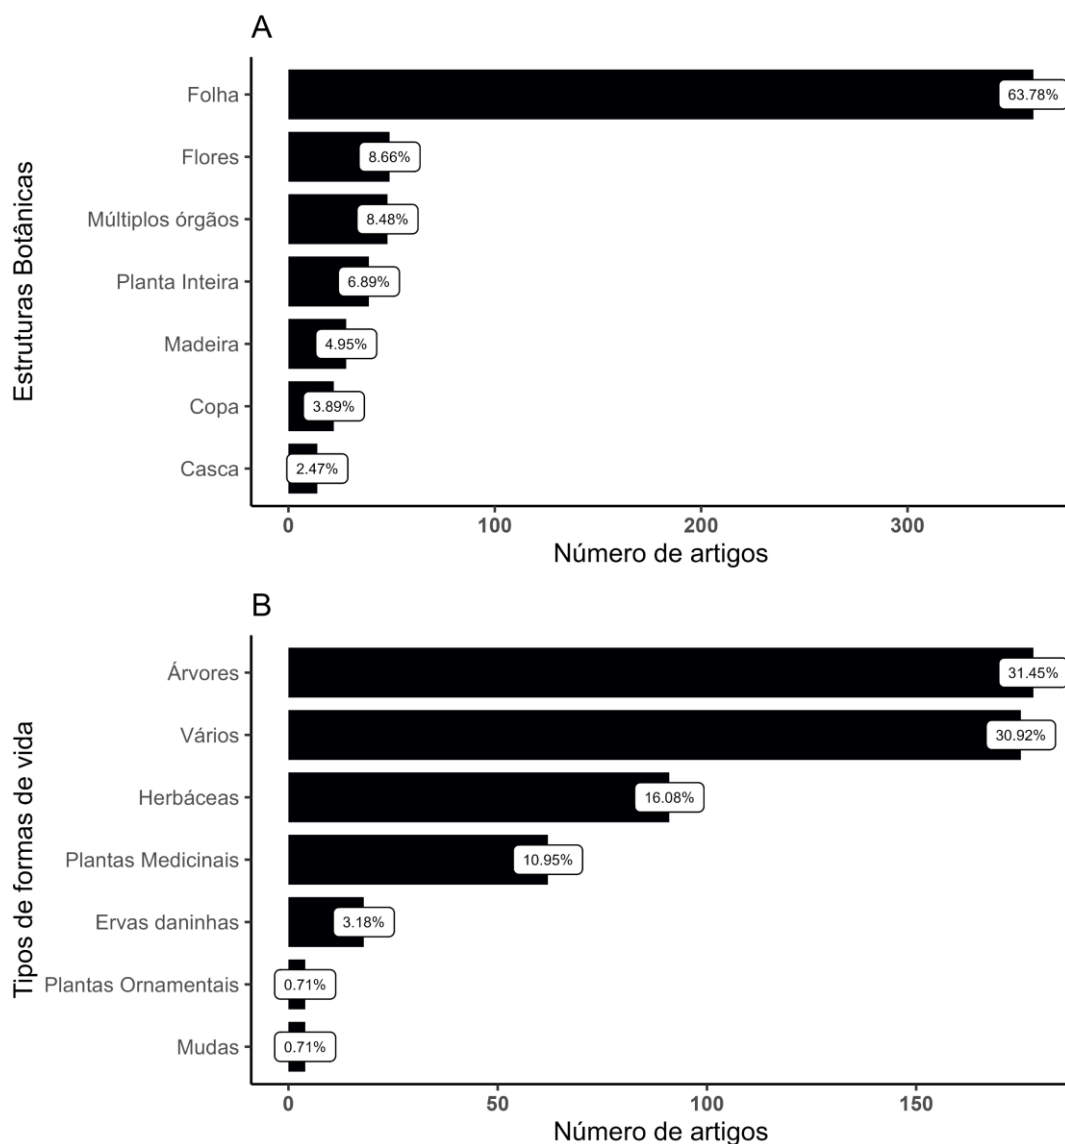


Figura 4: Contagem e percentual das 7 principais estruturas botânicas (A) e tipos de formas de vida (B) utilizados nos estudos sobre reconhecimento de plantas utilizando técnicas de visão computacional e aprendizado de máquina.

Com relação a origem das plantas que compõem os bancos de dados, cerca de 23,5% do total de artigos, utiliza bases de imagens de espécies arbóreas provenientes da China. Outros 15,2% do total de estudos, testa os algoritmos de reconhecimento de plantas em diferentes conjuntos de dados pertencentes a vários países. A Índia também ocupa posição de destaque, com 11,6% dos artigos, citando a utilização de plantas pertencentes a esse país (Figura 5A). Sobre os tipos de características extraídas dessas plantas, 45,4% dos artigos citam a extração de representações por meio do uso de técnicas de aprendizado profundo. As características de forma (31,4%) e textura (16,1%) também são comumente citados nas publicações, seja para estudos que analisam a sua utilização de maneira isolada ou em conjunto com outras características (Figura 5B).




Figura 5: Contagem e percentual dos países de origem dos conjuntos de imagens (A) e tipos de características extraídas das imagens (B) utilizados nos estudos sobre reconhecimento de plantas utilizando técnicas de visão computacional e aprendizado de máquina.

3.3. *Descritores de recursos e classificadores*

Para analisar o desenvolvimento das técnicas de extração de características (ou descritores) e dos classificadores, assim como o seu desempenho, em termos de acurácia, ao longo dos anos, os artigos foram agrupados em 3 períodos:

- (i) 1986 a 2008 – que compreende o período desde o primeiro artigo publicado sobre reconhecimento de plantas a partir de técnicas de visão computacional e aprendizado de máquina até o início do crescimento no número de publicações;
- (ii) 2009 a 2014 – em que o número de publicações aumenta, sendo observado o aprimoramento dos descritores e a introdução de novos algoritmos de aprendizado de máquina, como KNN e SVM para a tarefa de classificação de plantas; e

- (iii) 2015 a 2023 – período em que houve a introdução das CNNs nos estudos de reconhecimento de plantas através de imagens, o que aumentou o número de artigos publicados sobre essa temática.

Sobre os descritores mencionados nos estudos, no período de 1986 a 2008, as características de forma, que geralmente se referem a obtenção de estatísticas que representam a geometria de folhas ou flores, incluindo informações de bordas, cantos e contornos, foram os mais utilizados. Já no período de 2009 a 2014, além da forma, foram empregadas técnicas de extração de características de textura como os Padrões Binários Locais (Local Binary Pattern - LBP) e as Matrizes de Coocorrência de Níveis de Cinza (Gray Level Cooccurrence Matrix – GLCM). No período de 2015 a 2023, alguns estudos ainda utilizam os mesmos descritores, porém, o destaque foi para o grande quantitativo de artigos utilizando CNNs para a obtenção de representações das imagens (Figura 6).

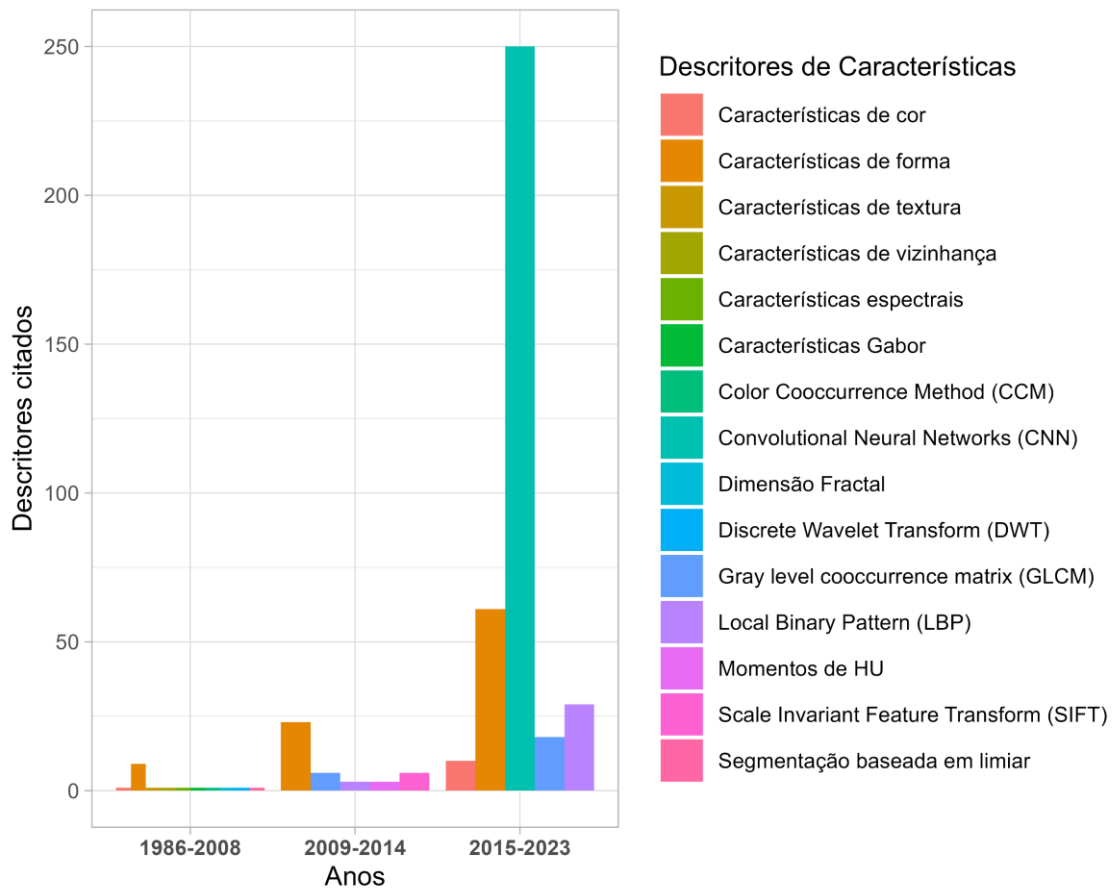


Figura 6: Contagem dos principais descritores de características das imagens de plantas citadas nos estudos, por período.

Com relação aos classificadores utilizados, no período de 1986 a 2008 a maioria dos artigos utilizaram ANNs como classificador nos modelos de reconhecimento de plantas, com média de acurácia de 89%. Entretanto os maiores desempenhos desse

período foram obtidos para técnicas de classificação mais específicas como as baseadas em características espectrais (96%) e o modelo geométrico Rhodonea (95%) (Figura 7).

No intervalo de 2009 a 2014 é observado um maior número de artigos publicados com diferentes tipos de classificadores como KNN, SVM e ANN, com média de acurácia de 88%, 86% e 92% respectivamente. Porém, a maior média de acurácia foi obtida para os estudos que utilizaram o algoritmo Random Forest (RF) (95%) (Figura 7C). A partir do ano de 2015 até meados de 2023, os estudos se concentraram na utilização das CNNs para a tarefa de reconhecimento de plantas em que 40,1%, do total de artigos, utilizaram esta técnica, alcançando uma média de 90% de acurácia (Figura 7). Dado o número expressivo de publicações utilizando esta técnica, foi verificado o seu crescimento ano a ano (entre 2015 e 2023), sendo constatado que o ano de 2022 foi o responsável pelo maior número de manuscritos (Figura 7B).

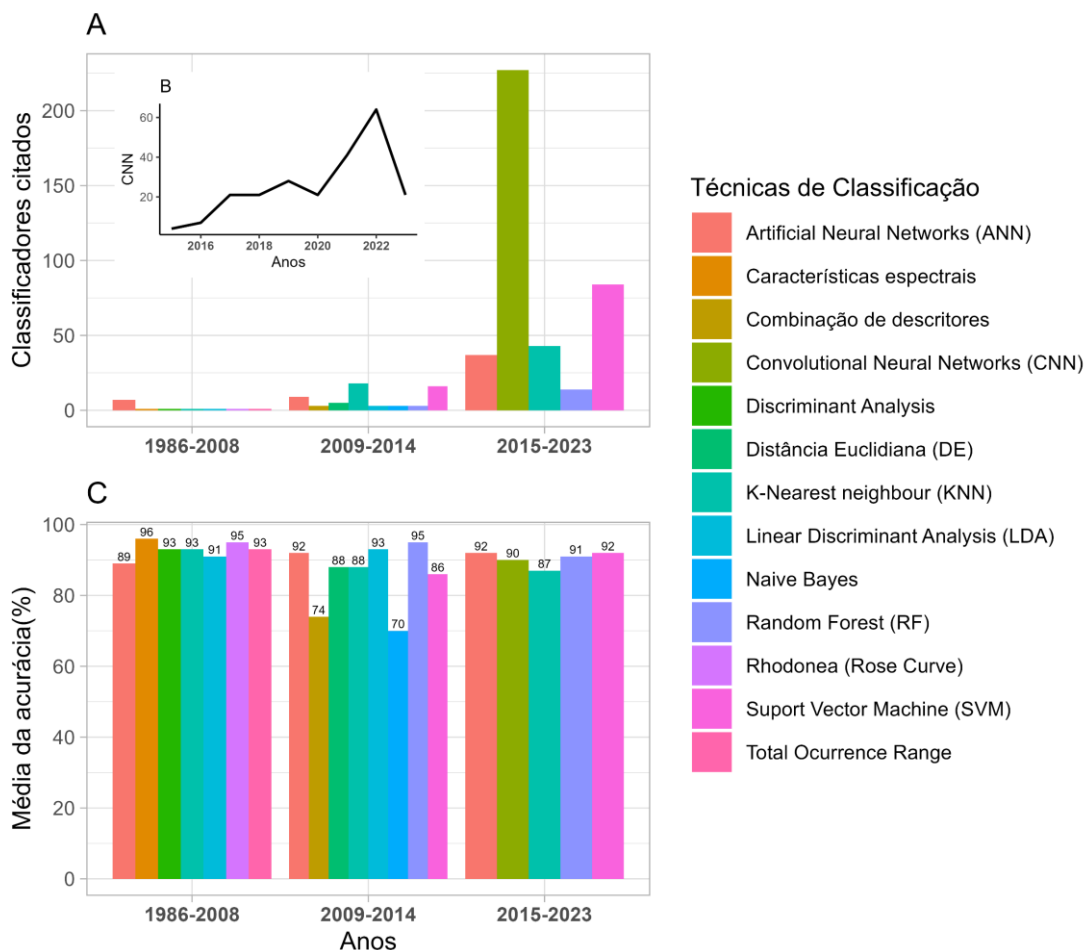


Figura 7: (A) Contagem dos principais classificadores por período; (B) número de artigos que utilizaram CNN entre os anos de 2015 e 2023; e (C) acurácia dos classificadores por período.

4. DISCUSSÃO

4.1. Base de dados

Estudos sobre o reconhecimento de plantas por técnicas de visão computacional e aprendizado de máquina tem crescido consideravelmente nas últimas décadas acompanhando o desenvolvimento das tecnologias ao longo dos anos. A maior parte das publicações são provenientes da Índia, e tem como foco a identificação de plantas medicinais, o que pode estar relacionado a aspectos culturais do país e ao seu sistema de medicina tradicional, também conhecido como ayurveda (Dileep; Pournami, 2019; Roopashree; Anitha, 2021; Ahila Priyadharshini; Arivazhagan; Arun, 2021; Blesslin Elizabeth; Baulkani, 2023).

O segundo país com o maior número de publicações é a China, considerado uma referência em inovação tecnológica, e mais recentemente, em tecnologias ambientais (Freire, 2022). Os artigos elaborados por autores chineses geralmente se concentram na exploração e experimentação de diversos algoritmos previamente documentados na literatura, bem como no aprimoramento desses métodos, utilizando bases de imagens compostas principalmente por espécies arbóreas ou arbustivas (Chen, 2019; Huang et al., 2019; He et al., 2022; Cui et al., 2023a).

Com relação aos periódicos que mais publicaram manuscritos, o *CEUR Workshop Proceedings* e o *Lecture Notes in Computer Science*, foram os que apresentaram o maior número de publicações, sendo periódicos de acesso livre para workshops de ciência da computação, sendo assim, os trabalhos publicados são todos referentes a conferências. O *Computers and Electronics in Agriculture* é um periódico de cobertura internacional voltado para o desenvolvimento de tecnologias para resolver problemas da agricultura, como a identificação automática de doenças e ervas daninhas em plantações. Já o *IEEE Access* é um periódico multidisciplinar que publica artigos de diversas áreas da ciência como Engenharia, Biologia, Medicina e Geociências.

4.2. Análise dos manuscritos

4.2.1. Estruturas Botânicas

Ao analisar os tipos de estruturas botânicas utilizadas, foi observada a predominância do uso de imagens de folhas para a classificação de plantas. Isto se deve ao fato de alguns autores considerarem que as folhas possuem características bem definidas e relativamente estáveis, como a presença de nervuras e o formato das margens,

tornando-as mais discriminativas que outras estruturas como flores, frutos ou cascas (Sahidan; Juha; Ibrahim, 2019; Zhang et al., 2022; Sun et al., 2023).

Kanda, Xia e Sanusi (2021) argumentam ainda que as folhas são de natureza bidimensional, o que é ideal para a identificação por meio de técnicas de processamento de imagens, diferentemente de flores e cascas que possuem características tridimensionais. Zhang et al. (2020) ressaltam outros fatores relacionados aos demais órgãos das plantas, como o curto período de floração e a suscetibilidade das cascas a agentes externos, que dificultam a utilização desses órgãos para a identificação por meio de imagens.

Apesar da preferência na utilização de imagens de folhas, boa parte dos estudos ainda utilizam imagens de flores para a identificação das plantas (Fatihahsahidan et al., 2019; Feng et al., 2019; Ran et al., 2021). O primeiro artigo utilizando flores encontrado pelas bases de dados foi publicado pelos autores Saitoh T. e Kaneko T. (2000), que utilizaram características de forma e ANNs para a construção de um modelo de reconhecimento, alcançando uma acurácia de 99,06%. Lee et al. (2013), empregaram os mesmos tipos de características, adotando como classificador o SVM, resultando em uma acurácia de 97,07%. Estes estudos mostram que a utilização de características de forma e algoritmos de aprendizado de máquina, são eficientes para a construção de modelos de reconhecimento de plantas baseados em imagens de flores.

No geral, os estudos adotam apenas uma estrutura botânica para a construção dos modelos computacionais. No entanto, considerando que em uma identificação tradicionalmente feita por um profissional botânico, seja em campo ou em herbário, são examinadas diversas estruturas, recentemente, algumas pesquisas têm avançado em técnicas que utilizam imagens de múltiplos órgãos das plantas (Šulc; Matas, 2017; Seeland et al., 2019; Wu et al., 2019). Esses avanços são possíveis graças ao desenvolvimento do aprendizado profundo, e mais precisamente das CNNs, que possibilitam um processo de aprendizagem eficiente através da compreensão automática dos padrões presentes nas imagens, para uma classificação mais acurada.

Neste sentido, a conferência Cross Language Evaluation Forum (ImageCLEF) organiza um desafio dedicado a identificação de plantas desde 2011, que objetiva promover o desenvolvimento de técnicas de classificação e disponibilizar bases de dados aos pesquisadores. A partir desse evento, foram encontrados resultados promissores relacionados aos principais problemas da identificação botânica por técnicas de processamento de imagens, como a necessidade de aumento de dados (Pawara et al.,

2017; Batchuluun; Nam; Park, 2022; Dourado Filho; Calumby, 2022) e a redução do esforço computacional através do processo de transferência de aprendizado (Transfer Learning) (Mehdipour Ghazi; Yanikoglu; Aptoula, 2017; Toma; Stefan; Ionescu, 2017; Pravinkrishnan et al., 2022).

Com relação aos estudos que utilizam outras estruturas botânicas, como madeira, casca ou copa, observa-se que ainda são pouco explorados no meio científico e estão associados ao reconhecimento de espécies florestais, considerando que nestes tipos de plantas, órgãos como folhas, flores ou frutos são de difícil acesso.

Trabalhos utilizando madeira geralmente são desenvolvidos com imagens macro e microscópicas, e tem como objetivo o desenvolvimento de sistemas automáticos de reconhecimento, para auxiliar em atividades de identificação de espécies florestais madeireiras exploradas ilegalmente (Fabijańska; Danek; Barniak, 2021; Figueroa-Mata et al., 2022; Park et al., 2022). Outros trabalhos que também tem como foco espécies florestais, são os que utilizam imagens da copa das árvores, e são voltados para as atividades de monitoramento, ou detecção e reconhecimento aéreo de espécies, sendo importantes para adquirir conhecimento acerca da biodiversidade de uma determinada região, para fins de preservação ou conservação (Fricker et al., 2019; Miyoshi et al., 2020; Beloiu et al., 2023).

Já os trabalhos utilizando imagens de casca são menos frequentes nas literaturas, porém, alguns autores argumentam que esta é uma das melhores abordagens no contexto de atividades de identificação de espécies florestais madeireiras (Bertrand; Cerutti; Tougne, 2017; Ido; Saitoh, 2019; Misra; Crispim-Junior; Tougne, 2020). Isto se deve ao fato de que a casca é uma das características que sofre menos alterações ao longo dos anos, e a aquisição das imagens é de fácil obtenção, ao contrário de folhas, flores ou frutos. Outra vantagem do uso da casca, está na possibilidade de obtenção de imagens sem um plano de fundo (background), eliminando a necessidade de etapas de segmentação, e facilitando o processamento das imagens.

4.2.2. Tipos de formas de vida e origem dos bancos de dados

Ao analisar os tipos de formas de vida comumente empregados nos estudos, foi observado que a maioria dos bancos de dados é composto por imagens de estruturas botânicas provenientes de árvores, como as espécies frutíferas (Adam; Amir, 2019; Ananth Pai et al., 2021), ou as encontradas em parques (Li et al., 2019; Chung; Chou; Li, 2021). Esses bancos de dados são geralmente criados pelos próprios autores, no entanto,

boa parte dos artigos utiliza dados disponíveis publicamente, que foram previamente construídos tanto utilizando imagens de plantas reais, quanto às encontradas na internet, gerando bases de imagens compostas por vários tipos de formas de vidas (arbóreas, arbustivas ou herbáceas) (Arshed et al., 2022; Cai et al., 2022; Devi et al., 2023).

As plantas herbáceas estão entre as espécies vegetais mais citadas nos estudos que utilizam imagens de folhas ou flores para a tarefa de reconhecimento, o que pode estar relacionado a facilidade de obtenção das imagens (Grinblat et al., 2016; Gogul; Kumar, 2017; Gu, 2022). Outra categoria de plantas bastante mencionada nos artigos são as medicinais, que envolvem espécies arbóreas ou herbáceas, e são empregadas para a construção de modelos computacionais que auxiliem a população local na identificação das espécies, o que é comum principalmente para os manuscritos provenientes da Índia (Almazaydeh; Salameen; Ellethy, 2018; Shelke; Mehendale, 2023; Thanikkal; Dubey; Thomas, 2023).

Uma vez que neste estudo foram contabilizados os tipos de formas de vida, assim como a sua origem, utilizados nos artigos, esse quantitativo é resultado dos bancos de dados empregados pelos autores. Desta forma, foi observado que muitos trabalhos empregam bases de imagens disponíveis publicamente, como a Flávia, que é uma das mais difundidas entre os estudos, sendo composta por imagens de folhas de espécies de árvores da China (Dudi, 2019; Eid; Hassanien; Kim, 2015; Kumar et al., 2019). Existem também os conjuntos de dados Oxford 17 e 102, composto por imagens de flores de plantas herbáceas do Reino Unido (Cheng; Tan, 2014; Pang et al., 2018; Ran et al., 2021).

Nota-se que existem poucos trabalhos utilizando bases de imagens de espécies florestais. O BarkNet, por exemplo, é um conjunto de dados constituído de imagens de casca de árvores de florestas do Canadá (Carpentier; Giguere; Gaudreault, 2018; Boudra; Yahiaoui; Behloul, 2022; Kim et al., 2022). Ghapar et al. (2021) utilizaram um conjunto de imagens de amostras de madeira de espécies tropicais, obtidas por meio do Instituto de Pesquisa Florestal da Malásia. Já Vizcarra et al. (2021) construíram um conjunto de imagens de folhas de espécies florestais da Amazônia Peruana.

É importante ressaltar que a ampla utilização de bases de imagens públicas, permite inferir que o principal foco dos pesquisadores está em aprimorar os algoritmos de reconhecimento de plantas, uma vez que, apenas as abordagens computacionais são alteradas. Isto também é constatado pela falta de informações a respeito da metodologia empregada para a identificação das plantas, em campo ou herbário, nos artigos, o que pode ocorrer por conta de a maioria desses estudos serem conduzidos por profissionais

da área da computação sem a presença de especialistas do campo da botânica, ou áreas afins.

Outra questão a ponderar é que, o uso de estruturas botânicas como folhas, flores ou de múltiplos órgãos, mostra que as pesquisas estão concentradas nas plantas mais relacionadas ao cotidiano social, considerando que a maioria das espécies são do tipo herbáceas, medicinais ou árvores de pequeno porte. Isto se deve a fatores como a modernização e o desenvolvimento de dispositivos móveis, uma vez que, os modelos computacionais de reconhecimento de plantas serão utilizados em aplicativos, possibilitando que a sociedade tenha um acesso mais rápido acerca das informações de identificação das plantas desejadas.

4.2.3. Tipos de características extraídas das imagens de plantas

Os tipos de características que são extraídas das imagens estão diretamente relacionados com a estrutura botânica que está sendo utilizada para o desenvolvimento do sistema de identificação. Por exemplo, em trabalhos que utilizam imagens de folhas é comum a extração de características de forma por ser uma característica mais predominante, porém, também existem trabalhos em que os autores utilizam recursos de textura e cor (Adinugroho; Sari, 2018; Mustafa et al., 2020; Aggarwal et al., 2021). Neste sentido, como a maioria dos estudos utiliza imagens de folhas, a forma, é o que predomina ao quantificar os tipos de características empregadas nos artigos.

As características de textura estão mais relacionados a trabalhos que utilizam imagens de madeira e casca, devido as suas propriedades visuais (Boudra; Yahiaoui; Behloul, 2018; Ghapar et al., 2021; Hwang; Sugiyama, 2021). Já a cor, é um recurso que apesar de estar mais presente em estudos que utilizam flores, também é utilizado em trabalhos de folhas e cascas, como uma estratégia de aumentar a acurácia da classificação. No entanto, a cor para estruturas como a folha, é uma característica pouco discriminativa (Wäldchen et al., 2018)

A extração de características das imagens é uma etapa presente nos estudos que utilizam abordagens tradicionais, em que algoritmos de visão computacional são empregados para extrair tais informações. Porém, com o desenvolvimento do aprendizado profundo, a maioria dos estudos estão focados na utilização de representações extraídas das imagens por meio das CNNs, o que elimina a necessidade de focar apenas em um tipo de característica.

4.2.4. Descritores de características e classificadores

O primeiro artigo encontrado pelas plataformas, data de 1986 sendo intitulado “*Machine Vision Image Processing for Plant Identification*” de Guyer D. E. e colaboradores, em que os autores utilizaram características espectrais de imagens de folhas de plantas herbáceas como vetor de entrada para o classificador Naive Bayes. Os autores concluíram que os resultados encontrados nessa pesquisa não foram muito promissores, porém, destacaram o potencial e a necessidade de desenvolver tecnologias para esta finalidade.

Nos anos seguintes, até cerca de 1999, o número de publicações foi reduzido, se limitando a estudos que utilizavam apenas imagens de folhas e se concentravam mais em algoritmos de extração de características de forma, através de estatísticas baseadas na geometria das imagens (Jia; Krutz; Gibson, 1991; Shiraishi; Sumiya, 1996). Neste período, os classificadores baseados em aprendizagem de máquina ainda não eram empregados, sendo a classificação das plantas feita com base em medidas de distância ou no intervalo total de ocorrências de padrões de recursos (Total Occurrence Range). Desta forma, neste período inicial, o principal interesse dos pesquisadores estava em como obter vetores de características que discriminassem eficientemente as informações baseadas nos pixels das imagens para posterior classificação.

A partir de 2000 até 2008, o número de publicações teve um leve aumento, com a inserção das ANNs como técnica de classificação, que combinadas com características de forma, resultaram em modelos computacionais com acurácia de até 98,6% (Hong Fu et al., 2004; Wu et al., 2007; Lin; Peng, 2008). As ANNs consistem em nós interconectados ponderados, organizados em várias camadas, imitando o processo de aprendizagem do cérebro humano, e atuando como um aproximador de função (Adinugroho; Sari, 2018; Huixian, 2020). Esta técnica foi a mais utilizada neste período, porém, outras técnicas como a Análise Discriminante Linear (Linear Discriminant Analysis - LDA) e K- Vizinhos mais próximo (K-Nearest Neighbor – KNN), também são apresentados nos estudos como classificadores.

No período de 2009 a 2014, além dos descritores de forma, os estudos começaram a adotar algoritmos para a extração de características de textura como LBP e GLCM. Basicamente, o GLCM é uma técnica que extrai informações de textura considerando a relação espacial de um pixel de referência e seu pixel vizinho em uma determinada distância d e ângulo θ (Khan; Narvekar, 2022). Já o LBP é um descritor invariante e simples, atuando em escala de cinza, que estabelece uma vizinhança ($n \times n$ pixels) em

torno de um pixel central, e depois relacionando este ao seu vizinho (Pradipkumar; Alagu Raja, 2022).

Estes descritores são mencionados na maioria dos estudos deste período, associados aos classificadores KNN e SVM. Ambos são métodos não paramétricos que apresentaram boa média de acurácia (88% e 86% respectivamente) para os manuscritos publicados, entretanto, a maior média de desempenho foi para o classificador Random Forest (RF), com 95% de acurácia. O RF é uma técnica de classificação que tem a capacidade de classificar grandes conjuntos de dados, gerando grupos de árvores de decisão, sendo que a saída é a classe selecionada pela maioria das árvores (Elhariri; El-Bendary; Hassanien, 2014).

As principais abordagens utilizadas neste período, a partir da combinação de descritores tradicionais de visão computacional e dos algoritmos de aprendizado de máquina, obtiveram desempenho variando de 70% a 95% de acurácia. Isso demonstra a alta capacidade dos descritores de extrair informações discriminativas das imagens de plantas, sejam elas baseadas em forma, textura ou cor. Também é observada a consolidação dos classificadores na tarefa de aprendizagem dos padrões presentes nos vetores gerados pelos descritores.

Apesar do bom desempenho dessas abordagens, observa-se uma tendência nos estudos publicados a partir de 2015, que começaram a adotar o uso de CNNs para o reconhecimento de plantas. As CNNs se constituem como técnicas que podem ser utilizadas tanto para o processo de construção dos modelos computacionais de ponta a ponta, ou seja, desde a extração de características das imagens (representações) até a classificação das plantas, quanto para realizar estas etapas de forma separada.

Desta forma, neste último período (de 2015 a 2023), os artigos publicados apresentam as seguintes abordagens: emprego das CNNs em todo o processo de reconhecimento (Bhat et al., 2021; Castro; Moreira; Luz, 2022; Custodio, 2023); utilização das CNNs para extração de vetores de representações das imagens, para então utilizá-los como entrada nos algoritmos de aprendizado de máquina (Espejo-Garcia et al., 2020; Ghosh et al., 2022; Karadeniz; Çelik; Başaran, 2023); e o uso das CNNs apenas como classificador utilizando as características provenientes de descritores tradicionais (Durairajah; Gobe; Muneer, 2018; Keskar; Maktedar, 2019; Meshram; Patil, 2022).

O desenvolvimento das CNNs se deve ao avanço dos sistemas de computação, como as GPUs, e aos grandes repositórios de conjuntos de dados disponíveis publicamente (Aqib Haqmi Abas et al., 2018). No entanto, o cenário ideal para um

sistema automático de reconhecimento de plantas, é que se tenha modelos que alcancem alta performance com um baixo custo computacional. Para isso, algumas arquiteturas de redes pré-treinadas, estão sendo utilizadas nos artigos como a VGG16, InceptionV3 e ResNet50 (Boston; Van Dijk, 2019; Chung; Chou; Li, 2021; Taslim et al., 2021). Estas redes são adaptadas para a realização da tarefa desejada, sendo, desta forma, uma abordagem conhecida como aprendizagem de transferência (Transfer Learning), que é baseada na aplicação do conhecimento aprendido no processo de treinamento de um determinado problema para outro diferente, porém, semelhante.

Depois das CNNs, que apresentaram uma média de acurácia de 90%, as abordagens mais utilizadas para a classificação de plantas, neste período (2015-2023), são as que empregam técnicas para extração de características de forma, as técnicas LBP e GLCM para textura, e as técnicas para extração de características de cor. Já os classificadores mais utilizados, e suas respectivas médias de acurácias foram SVM (92%), seguido de KNN (87%), ANN (92%) e RF (91%). Esses valores, demonstram a capacidade das abordagens tradicionais para a construção de modelos acurados, tendo a vantagem de serem de baixo custo computacional. No entanto, de acordo com o observado no presente trabalho, as CNNs se constituem como a principal linha de investigação dos autores, uma vez que é um método mais sofisticado, que abrange todas as etapas da construção de modelos computacionais de reconhecimento de plantas.

5. CONCLUSÕES

A pesquisa demonstra que estudos sobre o reconhecimento de plantas por abordagens de visão computacional e aprendizado de máquina vem crescendo consideravelmente nos últimos anos. A principal estrutura botânica utilizada nesses estudos são as folhas de plantas herbáceas ou árvores de pequeno porte, o que abre espaço para a necessidade de explorar o desenvolvimento de modelos computacionais utilizando outras estruturas, como flor, madeira e casca, uma vez que, uma identificação mais assertiva é realizada por meio da análise de diversos órgãos das plantas, além de plantas de maiores dimensões, como as amazônicas, por exemplo.

Outro ponto importante, diz respeito aos tipos de formas de vida que estão sendo empregados nos estudos. A maioria dos trabalhos utilizam plantas herbáceas, medicinais ou mesmo de árvores e arbustos de zonas urbanas, mais especificamente de parques, que fazem parte do cotidiano da sociedade promovendo lazer, bem-estar e saúde. Porém, é importante o desenvolvimento de sistemas automáticos de identificação para espécies

florestais, pois estes, podem contribuir em atividades de monitoramento ecológico, combate à exploração ilegal e, em outras ações de preservação e conservação da flora.

As abordagens tradicionais de construção de modelos computacionais apresentaram bom desempenho em termos de acurácia, demonstrando que essas técnicas podem ser usadas com êxito para esta tarefa. Apesar disso, os estudos demonstram que a tendência é aprimorar a utilização das CNNs, pois elas apresentam resultados eficientes de reconhecimento de plantas sem a necessidade de extensas etapas de processamento de imagens, como nas abordagens tradicionais. Além disso, ao contrário dos outros métodos, as CNNs permitem o reconhecimento das plantas a partir de diversas estruturas, o que é ideal para as tarefas de identificação.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- Adam, S., Amir, A., 2019. Fruit Plant Leaf Identification Feature Extraction Using Zernike Moment Invariant (ZMI) and Methods Backpropagation, in: 2019 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS). IEEE, pp. 225–230. <https://doi.org/10.1109/ICIMCIS48181.2019.8985219>
- Adinugroho, S., Sari, Y.A., 2018. Leaves classification using neural network based on ensemble features, in: 2018 5th International Conference on Electrical and Electronic Engineering (ICEEE). IEEE, pp. 350–354. <https://doi.org/10.1109/ICEEE2.2018.8391360>
- Aggarwal, S., Bhatia, M., Madaan, R., Pandey, H.M., 2021. Optimized Sequential model for Plant Recognition in Keras. IOP Conf. Ser. Mater. Sci. Eng. 1022, 012118. <https://doi.org/10.1088/1757-899X/1022/1/012118>
- Ahila Priyadharshini, R., Arivazhagan, S., Arun, M., 2021. Ayurvedic Medicinal Plants Identification: A Comparative Study on Feature Extraction Methods, in: Communications in Computer and Information Science. pp. 268–280. https://doi.org/10.1007/978-981-16-1092-9_23
- Ahmed, A., Hussein, S.E., 2020. Leaf identification using radial basis function neural networks and SSA based support vector machine. PLoS One 15, e0237645. <https://doi.org/10.1371/journal.pone.0237645>
- Ali, A.Y., Fahad, L.G., 2022. Multi-Organ Plant Classification Using Deep Learning, in: 2022 24th International Multitopic Conference (INMIC). IEEE, pp. 1–6. <https://doi.org/10.1109/INMIC56986.2022.9972979>
- Almazaydeh, L., Salameen, R., Ellethy, K., 2018. Herbal Leaf Recognition Using Mask-Region Convolutional Neural Network (Mask R-CNN). J. Theor. Appl. Inf. Technol. 100, 3664–3671.
- Amlekar, M.M., Gaikwad, A.T., 2019. Plant Classification Using Image Processing and Neural Network, in: Springer Verlag. pp. 375–384. https://doi.org/10.1007/978-981-13-1274-8_29
- Ananth Pai, K., Apoorva, B.R., Mendonca, D.S., Hegde, D.S., Hegde, R.B., 2021.

- Development of an Automated Plant Classification System Using Deep Learning Approach, in: *Lecture Notes in Electrical Engineering*. pp. 303–315. https://doi.org/10.1007/978-981-16-0443-0_25
- Aqib Haqmi Abas, M., Ismail, N., Ihsan Mohd Yassin, A., Nasir Taib, M., 2018. VGG16 for Plant Image Classification with Transfer Learning and Data Augmentation. *Int. J. Eng. Technol.* 7, 90–94. <https://doi.org/10.14419/ijet.v7i4.11.20781>
- Arafat, S.Y., Arshad, N., Khan, R., 2021. Holistic Based Plant Identification Using Deep Learning, in: *2021 16th International Conference on Emerging Technologies (ICET)*. IEEE, pp. 1–6. <https://doi.org/10.1109/ICET54505.2021.9689804>
- Ariyapadath, S., 2021. Plant Leaf Classification and Comparative Analysis of Combined Feature Set Using Machine Learning Techniques. *Trait. du Signal* 38, 1587–1598. <https://doi.org/10.18280/ts.380603>
- Arshed, M.A., Ghassan, H., Hussain, M., Hassan, M., Kanwal, A., Fayyaz, R., 2022. A Light Weight Deep Learning Model for Real World Plant Identification, in: *2022 Second International Conference on Distributed Computing and High Performance Computing (DCHPC)*. IEEE, pp. 40–45. <https://doi.org/10.1109/DCHPC55044.2022.9731841>
- Athapaththu, S.W., Piumi Ishanka, U.A., 2023. Plant Leaf Recognition Using Texture, Colour, and Vein Density Features, in: *2023 3rd International Conference on Advanced Research in Computing (ICARC)*. IEEE, pp. 102–107. <https://doi.org/10.1109/ICARC57651.2023.10145733>
- Atique, A., Karim, S., Shahid, S., Alamgir, Z., 2022. Identification of plant species through leaf vein morphometric and deep learning. *Pakistan J. Bot.* 54, 2195–2202. [https://doi.org/10.30848/PJB2022-6\(38\)](https://doi.org/10.30848/PJB2022-6(38))
- Batchuluun, G., Nam, S.H., Park, K.R., 2022. Deep Learning-Based Plant-Image Classification Using a Small Training Dataset. *Mathematics* 10, 3091. <https://doi.org/10.3390/math10173091>
- Beloiu, M., Heinzmann, L., Rehush, N., Gessler, A., Griess, V.C., 2023. Individual Tree-Crown Detection and Species Identification in Heterogeneous Forests Using Aerial RGB Imagery and Deep Learning. *Remote Sens.* 15, 1463. <https://doi.org/10.3390/rs15051463>
- Bertrand, S., Cerutti, G., Tougne, L., 2017. Bark Recognition to Improve Leaf-based Classification in Didactic Tree Species Identification, in: *Proceedings of the 12th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications*. SCITEPRESS - Science and Technology Publications, pp. 435–442. <https://doi.org/10.5220/0006108504350442>
- Bhat, S., Dsouza, P., Sharanyalaxmi, K., Shreeraksha, Tejasvini, Ananth, A., 2021. Classification of Plant Leaves of Western Ghats using Deep Learning, in: *2021 IEEE International Conference on Distributed Computing, VLSI, Electrical Circuits and Robotics (DISCOVER)*. IEEE, pp. 18–23. <https://doi.org/10.1109/DISCOVER52564.2021.9663698>
- Bisen, D., 2021. Deep convolutional neural network based plant species recognition through features of leaf. *Multimed. Tools Appl.* 80, 6443–6456. <https://doi.org/10.1007/s11042-020-10038-w>
- Blesslin Elizabeth, C.P., Baulkani, S., 2023. Novel Network for Medicinal Leaves

- Identification. *IETE J. Res.* 69, 1772–1782.
<https://doi.org/10.1080/03772063.2021.2016504>
- Boston, T., Van Dijk, A., 2019. Some experiments in automated identification of Australian plants using convolutional neural networks, in: *Proceedings of the 23rd International Congress on Modelling and Simulation (MODSIM2019)*. pp. 15–21.
- Bouchahma, M., Balushi, M. Al, Hosni, S. Al, Wardi, H. Al, 2019. Decision aid system for Omani medical herb leaves recognition using computer vision and artificial intelligence. *Int. J. Inf. Decis. Sci.* 11, 129.
<https://doi.org/10.1504/IJIDS.2019.101142>
- Boudra, S., Yahiaoui, I., Behloul, A., 2022. Tree trunk texture classification using multi-scale statistical macro binary patterns and CNN. *Appl. Soft Comput.* 118, 108473.
<https://doi.org/10.1016/j.asoc.2022.108473>
- Boudra, S., Yahiaoui, I., Behloul, A., 2018. Plant identification from bark: A texture description based on Statistical Macro Binary Pattern, in: *2018 24th International Conference on Pattern Recognition (ICPR)*. IEEE, pp. 1530–1535.
<https://doi.org/10.1109/ICPR.2018.8545798>
- Cai, X., Huo, Y., Chen, Y., Xi, M., Tu, Y., Sun, C., Sun, H., 2022. Real-Time Leaf Recognition Method Based on Image Segmentation and Feature Extraction. *Int. J. Pattern Recognit. Artif. Intell.* 36, 1–24.
<https://doi.org/10.1142/S0218001421540331>
- Carpentier, M., Giguere, P., Gaudreault, J., 2018. Tree Species Identification from Bark Images Using Convolutional Neural Networks, in: *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE, pp. 1075–1081.
<https://doi.org/10.1109/IROS.2018.8593514>
- CASTRO, P.H.N., Moreira, G.J.P., Luz, E.J. da S., 2022. An End-to-End Deep Learning System for Hop Classification. *IEEE Lat. Am. Trans.* 20, 430–442.
<https://doi.org/10.1109/TLA.2022.9667141>
- Chavan, S., Ford, J., Yu, X., Saniie, J., 2021. Plant Species Image Recognition using Artificial Intelligence on Jetson Nano Computational Platform, in: *2021 IEEE International Conference on Electro Information Technology (EIT)*. IEEE, pp. 350–354. <https://doi.org/10.1109/EIT51626.2021.9491893>
- Chen, H., 2019. Plant Leaves Recognition Combined PCA with AdaBoost.M1. *Int. J. Performability Eng.* 15, 1122–1130.
<https://doi.org/10.23940/ijpe.19.04.p7.11221130>
- Cheng, K., Tan, X., 2014. Sparse representations based attribute learning for flower classification. *Neurocomputing* 145, 416–426.
<https://doi.org/10.1016/j.neucom.2014.05.011>
- Chompookham, T., Gonwirat, S., Lata, S., Phiphaphaisit, S., Surinta, O., 2020. Plant Leaf Image Recognition using Multiple-grid Based Local Descriptor and Dimensionality Reduction Approach, in: *Proceedings of the 2020 The 3rd International Conference on Information Science and System*. ACM, New York, NY, USA, pp. 72–77. <https://doi.org/10.1145/3388176.3388180>
- Chung, Y., Chou, C.-A., Li, C.-Y., 2021. Central Attention and a Dual Path Convolutional Neural Network in Real-World Tree Species Recognition. *Int. J. Environ. Res. Public Health* 18, 961. <https://doi.org/10.3390/ijerph18030961>

- Cui, L., Chen, S., Mu, Y., Xu, X., Zhang, B., Zhao, X., 2023. Tree Species Classification over Cloudy Mountainous Regions by Spatiotemporal Fusion and Ensemble Classifier. *Forests* 14, 107. <https://doi.org/10.3390/f14010107>
- Cui, Z., Li, X., Li, T., Li, M., 2023. Improvement and Assessment of Convolutional Neural Network for Tree Species Identification Based on Bark Characteristics. *Forests* 14, 1292. <https://doi.org/10.3390/f14071292>
- Custodio, E.F., 2023. Classifying Philippine Medicinal Plants Based on Their Leaves Using Deep Learning, in: 2023 IEEE World AI IoT Congress (AIIoT). IEEE, pp. 0029–0035. <https://doi.org/10.1109/AIIoT58121.2023.10174335>
- D. E. Guyer, G. E. Miles, M. M. Schreiber, O. R. Mitchell, V. C. Vanderbilt, 1986. Machine Vision and Image Processing for Plant Identification. *Trans. ASAE* 29, 1500–1507. <https://doi.org/10.13031/2013.30344>
- Devi, R.M., Sangeetha, M., Sagana, C., Savitha, S., Hemalatha, P., Janani, N., Maamathi, K., 2023. Plant type classification based on leaves using Fusion based Support Vector Machine, in: 2023 International Conference on Computer Communication and Informatics (ICCCI). IEEE, pp. 1–6. <https://doi.org/10.1109/ICCCI56745.2023.10128587>
- Dileep, M.R., Pournami, P.N., 2019. AyurLeaf: A Deep Learning Approach for Classification of Medicinal Plants, in: TENCON 2019 - 2019 IEEE Region 10 Conference (TENCON). IEEE, pp. 321–325. <https://doi.org/10.1109/TENCON.2019.8929394>
- Dourado Filho, L.A., Calumby, R.T., 2022. Data Augmentation policies and heuristics effects over dataset imbalance for developing plant identification systems based on Deep Learning: A case study. *Rev. Bras. Comput. Apl.* 14, 85–94. <https://doi.org/10.5335/rbca.v14i2.13487>
- Dudi, B., 2019. Medicinal Plant Recognition based on CNN and Machine Learning. *Int. J. Adv. Trends Comput. Sci. Eng.* 8, 999–1003. <https://doi.org/10.30534/ijatcse/2019/03842019>
- Durairajah, V., Gobebe, S., Muneer, A., 2018. Automatic Vision Based Classification System Using DNN and SVM Classifiers, in: 2018 3rd International Conference on Control, Robotics and Cybernetics (CRC). IEEE, pp. 6–14. <https://doi.org/10.1109/CRC.2018.00011>
- Eid, H.F., Hassanien, A.E., Kim, T.-H., 2015. Leaf Plant Identification System Based on Hidden Naïve Bays Classifier, in: 2015 4th International Conference on Advanced Information Technology and Sensor Application (AITS). IEEE, pp. 76–79. <https://doi.org/10.1109/AITS.2015.28>
- Elhariri, E., El-Bendary, N., Hassanien, A.E., 2014. Plant classification system based on leaf features, in: 2014 9th International Conference on Computer Engineering & Systems (ICCES). IEEE, pp. 271–276. <https://doi.org/10.1109/ICCES.2014.7030971>
- Espejo-Garcia, B., Mylonas, N., Athanasakos, L., Fountas, S., Vasilakoglou, I., 2020. Towards weeds identification assistance through transfer learning. *Comput. Electron. Agric.* 171, 105306. <https://doi.org/10.1016/j.compag.2020.105306>
- Fabijańska, A., Danek, M., Barniak, J., 2021. Wood species automatic identification from wood core images with a residual convolutional neural network. *Comput. Electron. Agric.* 171, 105306. <https://doi.org/10.1016/j.compag.2020.105306>

- Agric. 181, 105941. <https://doi.org/10.1016/j.compag.2020.105941>
- FatihahSahidan, N., Khairi Juha, A., Mohammad, N., Ibrahim, Z., 2019. Flower and leaf recognition for plant identification using convolutional neural network. *Indones. J. Electr. Eng. Comput. Sci.* 16, 737. <https://doi.org/10.11591/ijeecs.v16.i2.pp737-743>
- Feng, J., Wang, Z., Zha, M., Cao, X., 2019. Flower Recognition Based on Transfer Learning and Adam Deep Learning Optimization Algorithm, in: *Proceedings of the 2019 International Conference on Robotics, Intelligent Control and Artificial Intelligence.* ACM, New York, NY, USA, pp. 598–604. <https://doi.org/10.1145/3366194.3366301>
- Figuroa-Mata, G., Mata-Montero, E., Valverde-Otárola, J.C., Arias-Aguilar, D., Zamora-Villalobos, N., 2022. Using Deep Learning to Identify Costa Rican Native Tree Species From Wood Cut Images. *Front. Plant Sci.* 13, 1–12. <https://doi.org/10.3389/fpls.2022.789227>
- Freire, Á. de A.M., 2022. ESTADO E INOVAÇÕES: O DESENVOLVIMENTO VERDE NA CHINA. *Rev. DA Soc. Bras. Econ. POLÍTICA* 63, 70–93.
- Fricker, G.A., Ventura, J.D., Wolf, J.A., North, M.P., Davis, F.W., Franklin, J., 2019. A Convolutional Neural Network Classifier Identifies Tree Species in Mixed-Conifer Forest from Hyperspectral Imagery. *Remote Sens.* 11, 2326. <https://doi.org/10.3390/rs11192326>
- Ghapar, H.A., Khairuddin, U., Yusof, R., Khairuddin, A.S.M., Ahmad, A., 2021. New Feature Extraction for Wood Species Recognition System via Statistical Properties of Line Distribution, in: *2021 International Conference on Electrical, Communication, and Computer Engineering (ICECCE).* IEEE, pp. 1–5. <https://doi.org/10.1109/ICECCE52056.2021.9514115>
- Ghosh, A., Roy, P., 2022. An automated model for leaf image-based plant recognition: an optimal feature-based machine learning approach. *Innov. Syst. Softw. Eng.* <https://doi.org/10.1007/s11334-022-00440-y>
- Ghosh, S., Singh, A., Kavita, Z., Jhanjhi, N., Masud, M., Aljahdali, S., 2022. SVM and KNN Based CNN Architectures for Plant Classification. *Comput. Mater. Contin.* 71, 4257–4274. <https://doi.org/10.32604/cmc.2022.023414>
- Ghosh, S., Singh, A., Kumar, S., 2023. PB3C-CNN: An integrated Parallel Big Bang-Big Crunch and CNN based approach for plant leaf classification. *Intel. Artif.* 26, 15–29. <https://doi.org/10.4114/intartif.vol26iss72pp15-29>
- Gogul, I., Kumar, V.S., 2017. Flower species recognition system using convolution neural networks and transfer learning, in: *2017 Fourth International Conference on Signal Processing, Communication and Networking (ICSCN).* IEEE, pp. 1–6. <https://doi.org/10.1109/ICSCN.2017.8085675>
- Grinblat, G.L., Uzal, L.C., Larese, M.G., Granitto, P.M., 2016. Deep learning for plant identification using vein morphological patterns. *Comput. Electron. Agric.* 127, 418–424. <https://doi.org/10.1016/j.compag.2016.07.003>
- Gu, F., 2022. Intelligent flower recognition system based on deep learning, in: Yang, S., Wu, G. (Eds.), *Third International Conference on Artificial Intelligence and Electromechanical Automation (AIEA 2022).* SPIE, p. 86. <https://doi.org/10.1117/12.2646860>
- Gulac, F., Bayazit, U., 2018. Plant and Phenology Recognition from Field Images Using

- Texture and Color Features, in: 2018 Innovations in Intelligent Systems and Applications (INISTA). IEEE, pp. 1–6. <https://doi.org/10.1109/INISTA.2018.8466300>
- Harjanti, T.W., Madenda, S., 2019. Development of feature extraction on leaf image for medicinal plants identification. *Int. J. Recent Technol. Eng.* 8, 163–168. <https://doi.org/10.35940/ijrte.B1040.0782S719>
- Hazra, D., Bhattacharyya, D., Kim, T., 2021. A Random Forest-Based Leaf Classification Using Multiple Features. pp. 227–239. https://doi.org/10.1007/978-981-15-9516-5_20
- He, J., Sun, Y., Yu, C., Cao, Y., Zhao, Y., Du, G., 2022. An Improved Wood Recognition Method Based on the One-Class Algorithm. *Forests* 13, 1350. <https://doi.org/10.3390/f13091350>
- Hidayat, T., Ramadona Nilawati, A., 2018. Identification of Plant Types by Leaf Textures Based on the Backpropagation Neural Network. *Int. J. Electr. Comput. Eng.* 8, 5389. <https://doi.org/10.11591/ijece.v8i6.pp5389-5398>
- Hong Fu, Zheru Chi, Dagan Feng, Jiatao Song, 2004. Machine learning techniques for ontology-based leaf classification, in: ICARCV 2004 8th Control, Automation, Robotics and Vision Conference, 2004. IEEE, pp. 681–686. <https://doi.org/10.1109/ICARCV.2004.1468909>
- Huang, Z., He, C., Wang, Z.-N., Xi, J., Wang, H., Hou, L., 2019. Cinnamomum Camphora Classification Based on Leaf Image Using Transfer Learning, in: 2019 IEEE 4th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC). IEEE, pp. 1426–1429. <https://doi.org/10.1109/IAEAC47372.2019.8997791>
- Huixian, J., 2020. The Analysis of Plants Image Recognition Based on Deep Learning and Artificial Neural Network. *IEEE Access* 8, 68828–68841. <https://doi.org/10.1109/ACCESS.2020.2986946>
- Hwang, S.-W., Sugiyama, J., 2021. Evaluation of image partitioning strategies for preserving spatial information of cross-sectional micrographs in automated wood recognition of Fagaceae. *J. Wood Sci.* 67, 18. <https://doi.org/10.1186/s10086-021-01953-z>
- Ido, J., Saitoh, T., 2019. CNN-based tree species identification from bark image, in: Yu, H., Pu, Y., Li, C., Pan, Z. (Eds.), Tenth International Conference on Graphics and Image Processing (ICGIP 2018). SPIE, p. 63. <https://doi.org/10.1117/12.2524213>
- Ihsan, M.F., Sunyoto, A., Arief, M.R., 2022. Gray Level Co-Occurrence Matrix Algorithm and Backpropagation Neural Networks for Herbal Plants Identification, in: 2022 5th International Conference on Information and Communications Technology (ICOIACT). IEEE, pp. 373–378. <https://doi.org/10.1109/ICOIACT55506.2022.9972087>
- Işık, Ş., Özkan, K., 2021. Overview of handcrafted features and deep learning models for leaf recognition. *J. Eng. Res.* 9. <https://doi.org/10.36909/jer.v9i1.7737>
- Jia, J., Krutz, G.W., Gibson, H.G., 1991. Evaluation of Machine Vision Algorithms for Locating Corn Plants, in: SAE Technical Papers. <https://doi.org/10.4271/911794>
- Kanda, P.S., Xia, K., Sanusi, O.H., 2021. A Deep Learning-Based Recognition Technique for Plant Leaf Classification. *IEEE Access* 9, 162590–162613.

<https://doi.org/10.1109/ACCESS.2021.3131726>

- Karadeniz, A.T., Çelik, Y., Başaran, E., 2023. Classification of walnut varieties obtained from walnut leaf images by the recommended residual block based CNN model. *Eur. Food Res. Technol.* 249, 727–738. <https://doi.org/10.1007/s00217-022-04168-8>
- Keskar, M., Maktedar, D.D., 2019. Enhancing Classifier Accuracy in Ayurvedic Medicinal Plants using WO-DNN. *Int. J. Eng. Adv. Technol.* 9, 6705–6714. <https://doi.org/10.35940/ijeat.A2001.109119>
- Khan, S., Narvekar, M., 2022. Novel fusion of color balancing and superpixel based approach for detection of tomato plant diseases in natural complex environment. *J. King Saud Univ. - Comput. Inf. Sci.* 34, 3506–3516. <https://doi.org/10.1016/j.jksuci.2020.09.006>
- Kim, T.K., Hong, J., Ryu, D., Kim, S., Byeon, S.Y., Huh, W., Kim, K., Baek, G.H., Kim, H.S., 2022. Identifying and extracting bark key features of 42 tree species using convolutional neural networks and class activation mapping. *Sci. Rep.* 12, 4772. <https://doi.org/10.1038/s41598-022-08571-9>
- Kumar, M., Gupta, S., Gao, X.-Z., Singh, A., 2019. Plant Species Recognition Using Morphological Features and Adaptive Boosting Methodology. *IEEE Access* 7, 163912–163918. <https://doi.org/10.1109/ACCESS.2019.2952176>
- Lee, H.H., Li, X.H., Chung, K.W., Hong, K.S., 2013. Flower Image Recognition Using Multi-Class SVM. *Appl. Mech. Mater.* 284–287, 3106–3110. <https://doi.org/10.4028/www.scientific.net/AMM.284-287.3106>
- Li, P., Gong, X., Hu, X., Shi, L., Xue, X., Guo, J., Xu, P., Gan, D., 2019. Plant Identification Based on Multi-branch Convolutional Neural Network with Attention. pp. 472–481. https://doi.org/10.1007/978-981-13-9917-6_45
- Lin, H., Peng, H., 2008. Machine Recognition for Broad-Leaved Trees Based on Synthetic Features of Leaves Using Probabilistic Neural Network, in: 2008 International Conference on Computer Science and Software Engineering. IEEE, pp. 871–877. <https://doi.org/10.1109/CSSE.2008.1333>
- Mehdipour Ghazi, M., Yanikoglu, B., Aptoula, E., 2017. Plant identification using deep neural networks via optimization of transfer learning parameters. *Neurocomputing* 235, 228–235. <https://doi.org/10.1016/j.neucom.2017.01.018>
- Meshram, R.S., Patil, N., 2022. Classification of Medicinal Plants Using Machine Learning. pp. 255–267. https://doi.org/10.1007/978-981-19-0011-2_24
- Misra, D., Crispim-Junior, C., Tougne, L., 2020. Patch-Based CNN Evaluation for Bark Classification. pp. 197–212. https://doi.org/10.1007/978-3-030-65414-6_15
- Miyoshi, G.T., Arruda, M. dos S., Osco, L.P., Marcato Junior, J., Gonçalves, D.N., Imai, N.N., Tommaselli, A.M.G., Honkavaara, E., Gonçalves, W.N., 2020. A Novel Deep Learning Method to Identify Single Tree Species in UAV-Based Hyperspectral Images. *Remote Sens.* 12, 1294. <https://doi.org/10.3390/rs12081294>
- Mustafa, M.S., Husin, Z., Tan, W.K., Mavi, M.F., Farook, R.S.M., 2020. Development of automated hybrid intelligent system for herbs plant classification and early herbs plant disease detection. *Neural Comput. Appl.* 32, 11419–11441. <https://doi.org/10.1007/s00521-019-04634-7>
- Pang, C., Yao, H., Sun, X., Zhao, S., Yu, W., 2018. Rediscover flowers structurally.

- Multimed. Tools Appl. 77, 7851–7863. <https://doi.org/10.1007/s11042-017-4679-9>
- Park, G., Lee, Y.-G., Yoon, Y., Ahn, J., Lee, J.-W., Jang, Y.-P., 2022. Machine Learning-Based Species Classification Methods Using DART-TOF-MS Data for Five Coniferous Wood Species. *Forests* 13, 1688. <https://doi.org/10.3390/f13101688>
- Pawara, P., Okafor, E., Schomaker, L., Wiering, M., 2017. Data Augmentation for Plant Classification. pp. 615–626. https://doi.org/10.1007/978-3-319-70353-4_52
- Pradipkumar, V.H., Alagu Raja, R.A., 2022. Automatic Identification of Tree Species from UAV Images Using Machine Learning Approaches. *J. Indian Soc. Remote Sens.* 50, 2447–2464. <https://doi.org/10.1007/s12524-022-01608-6>
- Pravinkrishnan, K., Naren, S., Ainsely, J., C Padma, P., Supraja, S., Prabavathy, B., Lekshmi, K., 2022. Classification of Plant Species Using AlexNet Architecture, in: *Proceedings of the Working Notes of CLEF 2022 - Conference and Labs of the Evaluation Forum*. Bologna, Italy, pp. 2087–2093.
- Ran, J., Shi, Y., Yu, J., Li, D., 2021. A Multi-Feature Convolution Neural Network for Automatic Flower Recognition. *J. Circuits, Syst. Comput.* 30, 1–15. <https://doi.org/10.1142/S0218126621502819>
- Roopashree, S., Anitha, J., 2021. DeepHerb: A Vision Based System for Medicinal Plants Using Xception Features. *IEEE Access* 9, 135927–135941. <https://doi.org/10.1109/ACCESS.2021.3116207>
- Sachar, S., Kumar, A., 2021. Survey of feature extraction and classification techniques to identify plant through leaves. *Expert Syst. Appl.* 167, 114181. <https://doi.org/10.1016/j.eswa.2020.114181>
- Sahidan, N.F., Juha, A.K., Ibrahim, Z., 2019. Evaluation of basic convolutional neural network and bag of features for leaf recognition. *Indones. J. Electr. Eng. Comput. Sci.* 14, 327. <https://doi.org/10.11591/ijeecs.v14.i1.pp327-332>
- Saitoh, T., Kaneko, T., 2000. Automatic recognition of wild flowers, in: *Proceedings 15th International Conference on Pattern Recognition. ICPR-2000*. IEEE Comput. Soc, pp. 507–510. <https://doi.org/10.1109/ICPR.2000.906123>
- Seeland, M., Rzanny, M., Boho, D., Wäldchen, J., Mäder, P., 2019. Image-based classification of plant genus and family for trained and untrained plant species. *BMC Bioinformatics* 20, 4. <https://doi.org/10.1186/s12859-018-2474-x>
- Shelke, A., Mehendale, N., 2023. A CNN-based android application for plant leaf classification at remote locations. *Neural Comput. Appl.* 35, 2601–2607. <https://doi.org/10.1007/s00521-022-07740-1>
- Shiraishi, M., Sumiya, H., 1996. Plant Identification From Leaves Using Quasi-Sensor Fusion. *J. Manuf. Sci. Eng.* 118, 382–387. <https://doi.org/10.1115/1.2831041>
- Šulc, M., Matas, J., 2017. Fine-grained recognition of plants from images. *Plant Methods* 13, 115. <https://doi.org/10.1186/s13007-017-0265-4>
- Sun, X., Xu, L., Zhou, Y., Shi, Y., 2023. Leaves and Twigs Image Recognition Based on Deep Learning and Combined Classifier Algorithms. *Forests* 14, 1083. <https://doi.org/10.3390/f14061083>
- Taslim, A., Saon, S., Mahamad, A.K., Muladi, M., Hidayat, W.N., 2021. Plant leaf identification system using convolutional neural network. *Bull. Electr. Eng. Informatics* 10, 3341–3352. <https://doi.org/10.11591/eei.v10i6.2332>

- Thanikkal, J.G., Dubey, A.K., Thomas, M.T., 2023. An Efficient Mobile Application for Identification of Immunity Boosting Medicinal Plants using Shape Descriptor Algorithm. *Wirel. Pers. Commun.* 131, 1189–1205. <https://doi.org/10.1007/s11277-023-10476-3>
- Thyagarajan, K.K., Kiruba Raji, I., 2019. A Review of Visual Descriptors and Classification Techniques Used in Leaf Species Identification. *Arch. Comput. Methods Eng.* 26, 933–960. <https://doi.org/10.1007/s11831-018-9266-3>
- Toma, A., Stefan, L.D., Ionescu, B., 2017. UPB HES SO @ PlantCLEF 2017: Automatic Plant Image Identification using Transfer Learning via Convolutional Neural Networks, in: *Working Notes of CLEF 2017 - Conference and Labs of the Evaluation Forum*.
- Vizcarra, G., Bermejo, D., Mauricio, A., Zarate Gomez, R., Dianderas, E., 2021. The Peruvian Amazon forestry dataset: A leaf image classification corpus. *Ecol. Inform.* 62, 101268. <https://doi.org/10.1016/j.ecoinf.2021.101268>
- Wäldchen, J., Mäder, P., 2018. Plant Species Identification Using Computer Vision Techniques: A Systematic Literature Review. *Arch. Comput. Methods Eng.* 25, 507–543. <https://doi.org/10.1007/s11831-016-9206-z>
- Wäldchen, J., Rzanny, M., Seeland, M., Mäder, P., 2018. Automated plant species identification—Trends and future directions. *PLOS Comput. Biol.* 14, e1005993. <https://doi.org/10.1371/journal.pcbi.1005993>
- Wang, Z., Cui, J., Zhu, Y., 2023. Review of plant leaf recognition. *Artif. Intell. Rev.* 56, 4217–4253. <https://doi.org/10.1007/s10462-022-10278-2>
- Wu, D., Han, X., Wang, G., Sun, Y., Zhang, H., Fu, H., 2019. Deep Learning with Taxonomic Loss for Plant Identification. *Comput. Intell. Neurosci.* 2019, 1–8. <https://doi.org/10.1155/2019/2015017>
- Wu, S.G., Bao, F.S., Xu, E.Y., Wang, Y.-X., Chang, Y.-F., Xiang, Q.-L., 2007. A Leaf Recognition Algorithm for Plant Classification Using Probabilistic Neural Network, in: *2007 IEEE International Symposium on Signal Processing and Information Technology*. IEEE, pp. 11–16. <https://doi.org/10.1109/ISSPIT.2007.4458016>
- Zhang, R., Zhu, Y., Ge, Z., Mu, H., Qi, D., Ni, H., 2022. Transfer Learning for Leaf Small Dataset Using Improved ResNet50 Network with Mixed Activation Functions. *Forests* 13, 2072. <https://doi.org/10.3390/f13122072>
- Zhang, Y., Cui, J., Wang, Z., Kang, J., Min, Y., 2020. Leaf Image Recognition Based on Bag of Features. *Appl. Sci.* 10, 5177. <https://doi.org/10.3390/app10155177>

Este capítulo está formatado de acordo com as normas da revista Ecological Informatics, disponível em: <https://www.sciencedirect.com/journal/ecological-informatics/publish/guide-for-authors>

ARTIGO 2

RECONHECIMENTO DE ESPÉCIES DE ÁRVORES AMAZÔNICAS A PARTIR DE IMAGENS DE CASCA USANDO PADRÕES BINÁRIOS LOCAIS E APRENDIZADO POR TRANSFERÊNCIA

Reconhecimento de espécies de árvores amazônicas a partir de imagens de casca usando padrões binários locais e aprendizado por transferência

Natally Celestino Gama ^{a*}; Luiz Eduardo Soares Oliveira^b; Samuel de Pádua Chaves e Carvalho^c; Pedro Luiz de Paula Filho^d; Márcia Orié Souza Hamada^e; Eduardo da Silva Leal^f; Deivison Venicio Souza^g

^aUniversidade Federal do Pará – UFPA, Programa de Pós Graduação em Biodiversidade e Conservação, Rua Cel. José Porfírio, 2515 - Centro, CEP: 68372040, Altamira, PA, Brazil, email: natallygama28@gmail.com.

^bUniversidade Federal do Paraná - UFPR, Departamento de Informática, Rua Cel. Francisco Heráclito dos Santos, 100 - Jardim das Américas CEP: 81531990, Curitiba, PR, Brazil, email: lesoliveira@gmail.com.

^cUniversidade Federal Rural do Rio de Janeiro - UFRRJ, Instituto Florestal. BR-465 - Km 7, CEP: 23897000, Seropedica, RJ, Brasil, email: samuel.carvalho@ufrj.br.

^dUniversidade Tecnológica Federal do Paraná - UTFPR, Avenida Brasil, 4232, Parque independência, Medianeira, PR, Brasil, email: plpf2004@gmail.com

^eUniversidade Federal do Pará - UFPA, Faculdade de Engenharia Florestal, Rua Cel. José Porfírio, 2515 - Centro, CEP: 68372040, Altamira, PA, Brazil, email: hamadaorie@hotmail.com.

^fUniversidade Federal Rural da Amazônia - UFRA, Campus Capanema, Avenida Barão de Capanema, s/n – CEP: 68700-665, Capanema, PA, Brazil, email: eduardo.leal@ufra.edu.br.

^gUniversidade Federal do Pará – UFPA, Faculdade de Engenharia Florestal, Rua Cel. José Porfírio, 2515 - Centro, CEP: 68372040, Altamira, PA, Brazil, email: deivisonvs@ufpa.br.

*Autor correspondente: e-mail: natallygama28@gmail.com

RESUMO

O uso de tecnologias baseadas em técnicas de visão computacional e inteligência artificial, podem contribuir para a melhoria da acurácia na identificação de espécies florestais em inventários florestais 100%, no âmbito do Manejo Florestal Sustentável - MFS para fins madeireiros. Neste sentido, o objetivo desta pesquisa foi desenvolver modelos para reconhecer espécies florestais madeireiras a partir de imagens digitais de cascas (ritidoma) de árvores exploradas comercialmente na Amazônia brasileira. As coletas foram realizadas em três unidades demonstrativas de MFS, localizadas em três municípios (Nova Maringá, Feliz Natal e Cotriguaçu) no estado do Mato Grosso (MT). O conjunto de imagens foi dividido em 80% para treinamento e 20% para teste. O conjunto de treinamento foi usado para aplicar o método de validação cruzada e a estratégia de pesquisa aleatória (random search), para encontrar os hiperparâmetros de ajuste ótimos de cada classificador. Foram avaliadas duas estratégias de extração de características das imagens digitais das cascas das árvores: i) Padrões Binários Locais – PBL (do inglês, Local Binary Pattern - LBP) com diferentes configurações; e ii) Redes Neurais Convolucionais (Convolutional Neural Networks - CNN) pré-treinadas (ResNet50, VGG16, InceptionV3 e MobileNetV2). Essas características foram extraídas de imagens originais com alta resolução (3024 x 4032 e 4000 x 5328 pixels) capturadas por dois dispositivos, e de subimagens de 256 x 256 pixels, extraídas aleatoriamente das imagens originais. Quatro algoritmos de aprendizado de máquina foram avaliados na tarefa de classificação de espécies: Support Vector Machine (SVM), Artificial Neural Networks (ANN), Random Forest (RF) e Linear Discriminant Analysis (LDA). Na abordagem tradicional, o melhor classificador foi construído usando de características extraídas das subimagens pelo operador $LBP_{16,2}^{u2}$ e o algoritmo ANN, atingindo na validação cruzada uma acurácia de aproximadamente 82% (d = 3,12%). Na abordagem de aprendizado por transferência, o classificador construído usando ResNet50 como extrator de características de subimagens e o algoritmo SVM, apresentou maior acurácia na validação cruzada (95%, d = 1,07%). Apesar da grande variabilidade intra e interespecífica nas características das cascas de árvores Amazônicas, a abordagem de aprendizado por transferência mostrou-se eficaz na extração de representações discriminativas e valiosas para o desenvolvimento de modelos de reconhecimento de espécies. Portanto, fica evidenciado o potencial da tecnologia como ferramenta auxiliar na realização de censos florestais, que pode contribuir com a diminuição dos erros de identificação de espécies no âmbito do MFS para fins madeireiros.

Palavras-chaves: Manejo florestal, censo florestal, identificação de espécies, aprendizado profundo

1. INTRODUÇÃO

A flora amazônica abrange aproximadamente 30% dos indivíduos arbóreos da América do Sul (Loyola et al., 2014; BFG, 2021), se destacando como uma das principais produtoras de madeira tropical do mundo, e apresenta um forte desenvolvimento do mercado madeireiro (Melo et al., 2017; Stragliotto et al., 2020), sendo necessário administrar os seus processos de exploração por meio de uma gestão sustentável.

O Manejo Florestal Sustentável (MFS) é uma das melhores formas de gestão dos recursos florestais, sendo definido como a administração da floresta para a obtenção de benefícios econômicos, sociais e ambientais, respeitando-se os mecanismos de sustentação do ecossistema objeto do manejo (CONAMA, 2009). Uma das exigências previstas no MFS é a realização do Inventário Florestal 100% (ou Censo Florestal), atividade essencial para a obtenção de informações quantitativas e qualitativas dos recursos florestais, como a identificação botânica (Hadlich et al., 2018; Encinas et al., 2022).

A identificação botânica, no entanto, não é uma atividade de fácil execução, devido às similaridades nas características morfológicas interespecíficas, requerendo conhecimento especializado e a coleta de material botânico (folhas, flores, frutos e sementes) para comparação em herbário e, por conseguinte, alcançar uma identificação correta (Engel et al., 2016; Lang et al., 2017). No entanto, no âmbito do MFS para fins madeireiros na Amazônia brasileira, a identificação de espécies é comumente realizada por pessoas conhecidas por "mateiros", que possuem conhecimento ecológico local e identificam as espécies por nomes vernaculares (comuns), baseado em características morfológicas das árvores, como cor, cheiro, textura e presença ou não de exsudatos no tronco (Procópio and Secco, 2008; Souza et al., 2020).

A identificação de espécies apenas por nomes vernaculares pode contribuir para a ocorrência de alguns problemas, como a exploração indevida de espécies ameaçadas de extinção e a comercialização de espécies de maneira enganosa (Menezes et al., 2015; Novaes et al., 2023). Outro principal problema é a conversão de nomes vernaculares, obtidos em campo, para nomes científicos, a partir de listas pré-existentes fornecidas por órgãos ambientais, acarretando diversos erros no MFS para fins madeireiros (Lacerda and Nimmo, 2010).

Estes erros são reportados, por exemplo, nos estudos de Cysneiros et al. (2018) e Ferreira et al. (2020), que relataram a presença de apenas nomes vernaculares em processos de Planos de Manejo Florestal Sustentável (PMFS), erros na grafia e uso de

nomenclaturas desatualizadas, diversos nomes vernaculares associados a um único nome científico, e táxons com identificação incompleta relacionados as espécies, gêneros e famílias de interesse comercial. Ademais, destacaram que a maioria destes erros, ocorrem devido a variação de dialetos entre regiões ou a falta de fiscalização por parte de órgãos competentes, com impactos ecológicos e econômicos negativos e afetando os princípios do MFS.

Neste contexto, tecnologias baseadas em visão computacional e/ou inteligência artificial, podem contribuir para a correta identificação de espécies da flora, através da construção de modelos computacionais de reconhecimento (ex.: Paula Filho et al., 2014; Carpentier et al., 2018a, Souza et. al., 2020). Na abordagem tradicionalmente utilizada, estes modelos são construídos utilizando algoritmos de visão computacional para extrair características de imagens das plantas (Gogul and Kumar, 2017; Ghosh and Roy, 2022a; Ran et al., 2021).

Os algoritmos podem ser baseados em características específicas das imagens, como os Padrões Binários Locais (do inglês, Local Binary Patterns – LBP) que são baseados em características de textura, ou envolver o uso de aprendizagem profunda, como no caso das Redes Neurais Convolucionais (do inglês, Convolutional Neural Network – CNNs) que extraem representações automáticas das imagens (Fekri-Ershad, 2020; Villaruz, 2021; Pravin and Deepa, 2022). Posteriormente, essas características são usadas como vetores de entrada para algoritmos de aprendizado de máquina, como as Redes Neurais Artificiais (Artificial Neural Networks - ANN) e as Máquinas de Vetores de Suporte (Support Vector Machine - SVM) (Pearline; Kumar; Harini, 2019; Kaya et al., 2019; Kumar et al., 2019).

A maioria dos modelos de reconhecimento são baseados em imagens digitais de estruturas como as folhas das plantas (ex.: Turkoglu; Hanbay; 2019; Keivani et. al., 2020; Huixian, 2020; Bisen, 2020; Chen; Wang, 2020; Wang et al., 2022), imagens macro e microscópicas de madeira (ex.: Paula Filho et al., 2014; Dias; Martins, 2018; Souza et. al., 2020; Vieira et al., 2022) e imagens das cascas das árvores (ex.: Carpentier et al., 2018a; Misra et al., 2020; Remeš and Haindl, 2019). No entanto, no contexto do MFS na Amazônia brasileira, as imagens das cascas das árvores são mais facilmente obtidas, devido à dificuldade em capturar imagens de outras estruturas, como folhas, flores, frutos e sementes, que dependem da fenologia e da altura das árvores.

A utilização destas estruturas morfológicas para a construção de modelos de reconhecimento, tem como principal intuito o desenvolvimento de aplicativos destinados

a dispositivos móveis, que podem ser usados para auxiliar no reconhecimento de espécies de plantas em diferentes contextos, como na identificação de plantas medicinais ou em atividades de fiscalização madeireira (Bertrand et al., 2017; de Geus et al., 2021; Taslim et al., 2021; He et al., 2022; Thanikkal et al., 2023).

No entanto, no âmbito do MFS para fins madeireiros, ainda não existe um sistema automático para reconhecer espécies comerciais da flora Amazônica, e que possa ser usado como ferramenta auxiliar na identificação de espécies durante a atividade de inventário florestal 100%. Portanto, o objetivo desta pesquisa é desenvolver e avaliar modelos de reconhecimento de espécies florestais, usando diferentes técnicas de extração de características de imagens digitais de cascas (ritidoma), e algoritmos de aprendizado de máquina, visando a melhoria da acurácia na identificação de árvores no Manejo Florestal Sustentável para fins madeireiros.

2. MATERIAL E MÉTODOS

2.1. Áreas de estudo

Os dados foram coletados em três Unidades Demonstrativas (UDs) de Manejo Florestal Sustentável (MFS) para fins madeireiro, localizadas em três municípios do estado do Mato Grosso (Figura 1): UD1- Fazenda Pérola (Nova Maringá); UD2 - Fazenda Boa Esperança (Feliz Natal); e UD3 - Fazenda São Nicolau (Cotriguaçu).

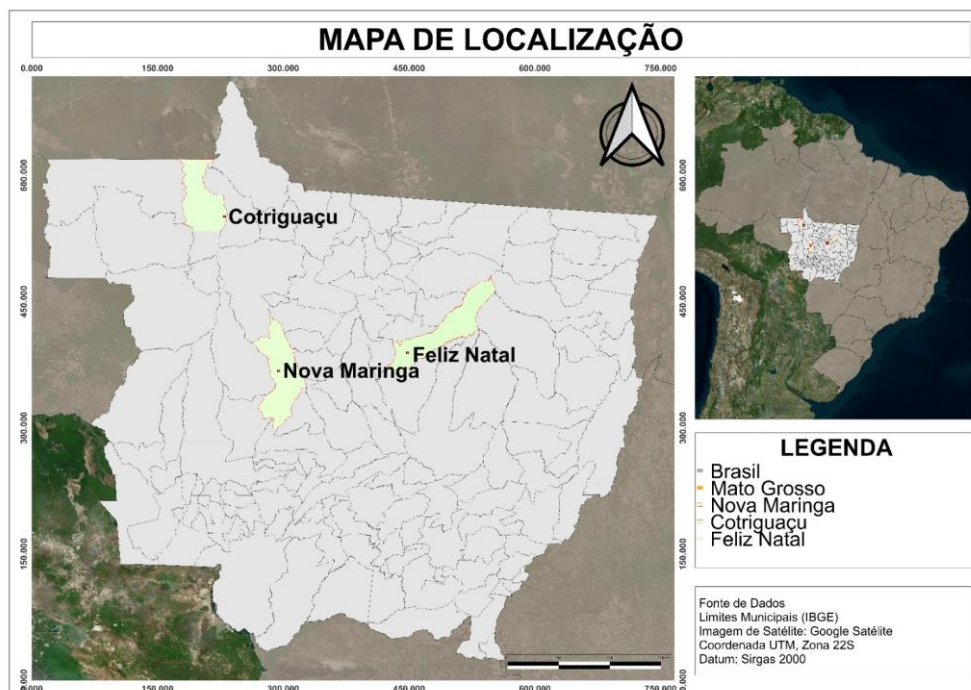


Figura 1: Localização geográfica das áreas de coleta de dados, no estado do Mato Grosso – MT.

No estado do Mato Grosso a vegetação é constituída por elementos dos biomas Pantanal, Cerrado e Amazônia, sendo que este último ocupa cerca de 53,5% do território (Silveira et al., 2017). Na região que faz parte do bioma amazônico, as tipologias florestais predominantes são as Florestas Ombrófilas Densas e Abertas, e as Florestas Estacionais, em que a média de temperatura é entre 25,7°C e 24,3°C com precipitação anual entre 2000 e 2500 mm (Borges et al., 2014; Benini et al., 2016).

A figura 2 apresenta um fluxograma abordando desde a etapa de coleta das imagens até a obtenção dos melhores modelos de reconhecimento com base nas métricas de desempenho, para uma melhor compreensão da metodologia empregada neste estudo.

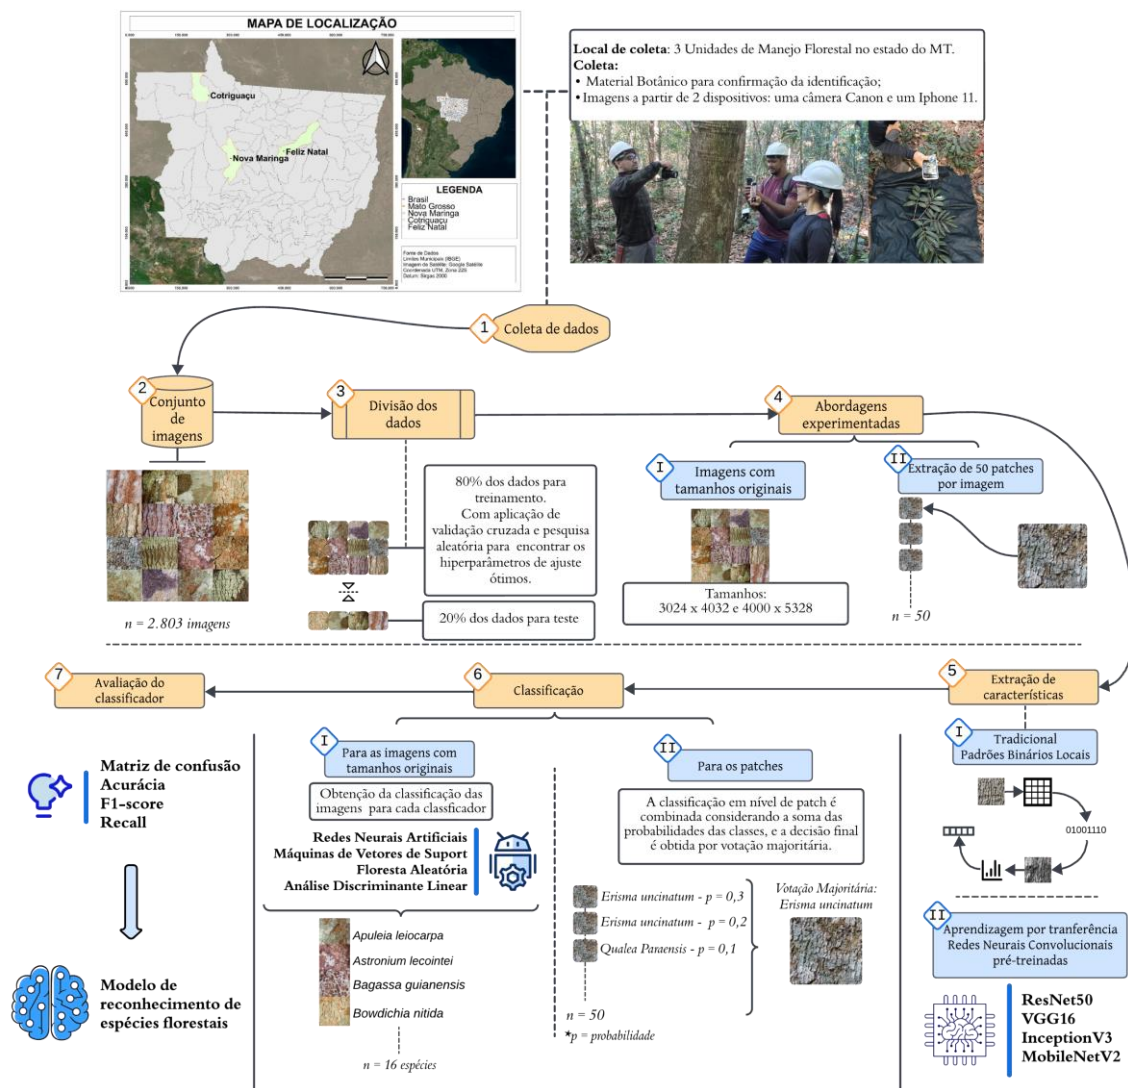


Figura 2: Fluxograma representativo da metodologia empregada neste estudo.

2.2. Aquisição de imagens

As espécies foram selecionadas com base na lista das espécies florestais de maior interesse comercial do Estado do Mato Grosso, disponibilizada pelo Centro das Indústrias

Produtoras e Exportadoras de Madeira do Mato Grosso – CIPEM, e considerando a ocorrência e abundância dos indivíduos nas áreas de coleta.

Em campo, foram coletadas imagens de cascas (ritidoma) de 10 árvores por espécie, usando dois dispositivos: uma câmera Canon e um dispositivo iOS iPhone 11, obtendo imagens com resoluções de 3024 x 4032 e 4000 x 5328, respectivamente (Figura 3). Nas árvores, a região em que as imagens foram capturadas variou em uma faixa de altura de 30 cm a 1,40 m de altura do solo, e uma distância entre 20cm e 40cm do dispositivo para o tronco, a depender das condições encontradas em campo.

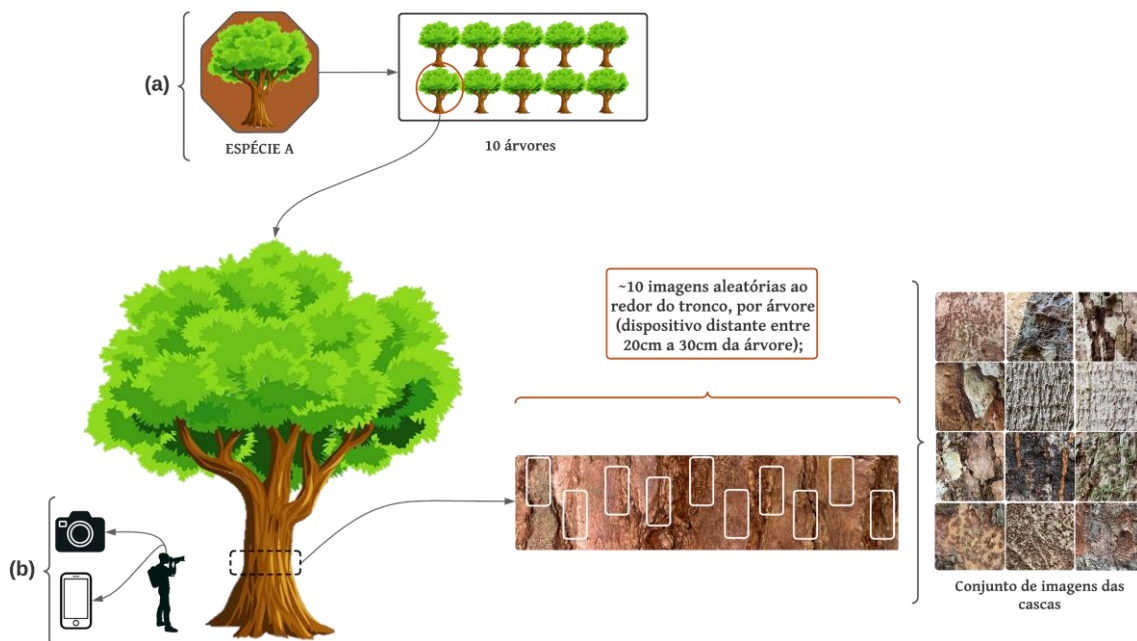


Figura 3: Representação dos procedimentos de coleta para a construção do conjunto de imagens de casca das árvores comerciais de espécies florestais amazônicas.

Muitos fatores dificultaram a aquisição de imagens, por exemplo, a baixa luminosidade (ou mesmo o excesso, devido a incidência direta da luz solar no tronco da árvore), a presença de musgos (ou líquens) e cupins nas cascas das árvores, e entre outros. Portanto, em regiões da floresta com baixa luminosidade foi utilizado um refletor (YN600L II – Pro Led Vídeo Light) para melhorar as condições de luz para a captura da imagem (Figura 4). Além disso, em árvores com grande incidência de musgos, líquens ou cupins, buscou-se, quando possível, regiões do tronco livres desses seres vivos, visando apenas evidenciar as características das cascas das árvores na imagem capturada.



Figura 4: (A) região com baixa luminosidade; (B) uso do refletor.

As imagens adquiridas foram cuidadosamente avaliadas para identificar problemas na qualidade ou presença de elementos indesejáveis que pudessem afetar a extração de características e, posterior, aprendizado dos modelos. Em geral, apesar dos esforços de campo, muitas imagens apresentaram desfoque e luminosidade inadequada. No total, a base de imagens foi composta por 2.803 imagens de cascas de árvores, pertencentes a 16 espécies, 16 gêneros e 9 famílias (Tabela 1). Na figura 5 estão amostras de imagens das cascas das 16 espécies de árvores.

Tabela 1: Família, nome científico, nome vernacular, quantidade de amostra e imagens por espécie.

ID	Família	Nome científico	Nome vernacular	Amostras	Coletas botânicas	n
1	Fabaceae	<i>Apuleia leiocarpa</i> (Vogel) J. F. Macbr.	Garapeira	10	5	155
2	Anacardiaceae	<i>Astronium lecointei</i> Ducke	Muiracatiara	10	5	182
3	Moraceae	<i>Bagassa guianensis</i> Aubl.	Tatajuba	10	5	185
4	Fabaceae	<i>Bowdichia nitida</i> Spruce ex Benth.	Sucupira	10	5	194
5	Meliaceae	<i>Cedrela odorata</i> L.	Cedro-Rosa	10	5	198
6	Fabaceae	<i>Dipteryx odorata</i> (Aubl.) Forsyth f.	Cumaru	10	5	149
7	Vochysiaceae	<i>Erismia uncinatum</i> Warm.	Cedrinho	10	5	158
8	Goupiaceae	<i>Goupia glabra</i> Aubl.	Cupiúba	10	5	162
9	Fabaceae	<i>Hymenolobium petraeum</i> Ducke	Angelim-Pedra	10	5	179
10	Lauraceae	<i>Mezilaurus itauba</i> (Meisn.) Taub. ex Mez	Itauba	10	6	164
11	Fabaceae	<i>Parkia pendula</i> (Willd.) Benth. ex Walp.	Angelim-Saia	10	5	183
12	Burseraceae	<i>Protium acrense</i> Daly	Amescla-Aroeira	10	5	188
13	Vochysiaceae	<i>Qualea paraensis</i> Ducke	Cambara	10	5	168
14	Simaroubaceae	<i>Simarouba amara</i> Aubl.	Marupá	10	5	197
15	Burseraceae	<i>Trattinnickia burserifolia</i> Mart.	Amescla	10	7	176
16	Fabaceae	<i>Vatairea sericea</i> (Ducke) Ducke	Angelim-amargoso	10	5	165
<i>Total</i>				160	83	2.803



Figura 5: Amostras de imagens das cascas das 16 espécies florestais amazônicas coletadas.

2.3. Identificação de espécies e coleta de material botânico

Em campo, a identificação de espécies é uma tarefa complexa, porém, fundamental para garantir a correta rotulagem das imagens e, por conseguinte, a construção de um sistema de reconhecimento de espécies confiável. Portanto, a identificação de espécies foi realizada por um Parobotânico, que realizou a escalada de no mínimo cinco árvores por espécie para coleta de material botânico (folhas, flores, sementes e frutos – alguns não tinham todas as estruturas), com amostragem de 83 espécimes de 16 espécies (Figura 6).

Todo material botânico foi prensado e, posteriormente, exsiccatas foram montadas para envio ao Herbário Felisberto Camargo (HFC) da Universidade Federal Rural da Amazônia para a confirmação da identificação, e as informações referentes aos registros das amostras podem ser consultadas no anexo 1. Além disso, de cada árvore foram

medidos o diâmetro a 1,30m do solo ($d_{1,3}$), a altura total da árvore com clinômetro Haglof e espessura da casca (Figura 7).



Figura 6: (A) escalada e coleta de material botânico; (B) montagem das exsicatas.



Figura 7: (A) medição do diâmetro; (B) obtenção da altura total da árvore com clinômetro Haglof; e (C) espessura da casca.

2.4. Extração de subimagens (patches)

As imagens originais que compõem o conjunto de dados possuem alta resolução (3024 x 4032 e 4000 x 5328 pixels), o que pode dificultar o processo de extração de características locais relevantes e, por sua vez, a obtenção de modelos mais acurados, sobretudo, em abordagens que utilizam CNNs. Assim, neste estudo, uma estratégia adotada foi extrair subimagens aleatórias de cada imagem original de alta resolução, potencializando a extração de características relevantes e, ao mesmo tempo, aumentando a dimensionalidade do conjunto de dados.

A determinação no número de subimagens (patches) pode variar a depender do problema de classificação e dos recursos computacionais disponíveis. Por exemplo, Misra et al. (2020) extraíram 9 patches por imagem em um problema de classificação de casca de árvores, utilizando um conjunto com 101 classes. Maruyama et al. (2018) extraíram 80 patches por imagem, em um problema de classificação com 44 classes. Neste estudo,

o conjunto de imagens de casca é composto por apenas 16 classes, porém, devido ao alto custo computacional optou-se por extrair apenas 50 patches por imagem.

Portanto, neste estudo, foram adotados os seguintes procedimentos para a extração das subimagens:

1. Redimensionamento: Inicialmente, as imagens originais de alta resolução foram redimensionadas na proporção de 20%, visando otimizar o pré-processamento, e garantir a manutenção das características discriminativas; e
2. Extração: Em seguida, foram extraídas 50 subimagens (patches) de tamanho 256 x 256 pixels de cada imagem original. Portanto, um novo conjunto foi formado com 140.150 subimagens extraídas das 2.803 imagens originais. Estas foram submetidas ao processo de extração de características e, posterior, construção dos modelos de classificação.

A decisão sobre o tamanho das subimagens (256 x 256 pixels) foi ponderada de acordo com as dimensões que são requeridas das imagens de entrada nas CNNs. Por exemplo, a rede ResNet50 requer imagens de entrada com tamanho 224 x 224 pixels. Já a InceptionV3 recebe como entrada imagens de até 299 x 299 pixels.

Nesta abordagem, a decisão final da classe da imagem é alcançada por meio de votação majoritária, uma técnica comum em problemas de classificação (Maruyama et al., 2018; Misra et al., 2020; Robert et al., 2020). Portanto, para cada subimagem ($n = 50$) de uma imagem original foi obtida a máxima probabilidade de classe e, em seguida, a decisão final da classe da imagem foi obtida pela soma de probabilidades.

2.5. Extração de características das imagens originais e subimagens

O processo de extração de características constitui uma etapa importante para o sucesso da modelagem de classificadores automáticos (Souza et al., 2020). Assim, foram avaliadas duas estratégias de extração de características das imagens digitais das cascas das árvores: i) Padrões Binários Locais (do inglês, Local Binary Pattern - LBP); e ii) Redes Neurais Convolucionais (do inglês, Convolutional Neural Networks - CNN) pré-treinadas (ResNet50, VGG16, InceptionV3 e MobileNetV2). Essas características foram extraídas de imagens originais com alta resolução (3024 x 4032 e 4000 x 5328 pixels) capturadas por dois dispositivos (CANON e iOS iPhone 11) e de subimagens de 256 x 256 pixels extraídas aleatoriamente das imagens originais.

2.5.1. Padrões Binários Locais (Local Binary Patterns – LBP)

O LBP (Local Binary Patterns) é um descritor de textura invariante simples e poderoso na escala de cinza (Ojala et al., 1996). Sua abordagem proporciona uma metodologia integrada para modelos estatísticos e estruturais. Cada pixel é associado a um código de textura primitiva que se ajusta de forma ideal ao contexto local. Isso viabiliza a detecção de elementos primitivos, tais como pontos, bordas, cantos e outros.

Originalmente, em sua primeira versão proposta por Ojala et al. (1994) para a realização dos cálculos do operador LBP são consideradas as seguintes etapas:

1. Vizinhança: é estabelecida uma vizinhança de 3x3 pixels em torno de um pixel central (Fig.8a);
2. Limiarização: limiarize os valores dos 8 pixels vizinhos em comparação com a intensidade do pixel central. Se o valor do pixel central for maior ou igual ao vizinho é atribuído valor “1”, caso contrário, é atribuído valor “0” gerando assim um código binário de 8 dígitos (11001101) (Fig.8b);
3. Pesos: os valores do código binário são multiplicados por pesos (1, 2, 4, 8, 16, 32, 64, 128) (Fig.8c);
4. Padrão LBP: o novo valor do pixel central será resultante da soma dos valores obtidos na etapa 3 (Fig.8d).




Figura 8: Um exemplo do cálculo do algoritmo LBP original.

Matematicamente um código LBP para determinado pixel é calculado da seguinte forma:

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(x_p - x_c) 2^p \quad s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad Eq. (01)$$

Em que: R é a resolução espacial do operador; P é a quantidade de vizinhos circulares simétricos; x_c representa o pixel central; x_p Representa os pixels vizinhos; e $s(x)$ é a função de limiar.

Em 2002, Ojala, Pietikainen e Maenpaa propuseram os chamados Padrões Binários Locais Uniformes e Invariantes a Rotação (*Local Binary Pattern Rotation*

Invariante Uniform – LBP_{P,R}^{riu2}). Nesta extensão, uma métrica de uniformidade é adotada: em que u é o número de transições bit a bit de 0 a 1 ou vice e versa, quando o padrão do bit é percorrido de maneira circular, sendo assim, um código LBP é considerado uniforme se a medida de uniformidade u é no máximo 2.

Neste estudo, as imagens coloridas foram convertidas para a escala de cinza, e três configurações do LBP uniforme e invariante ($LBP_{8,1}^{riu2}$, $LBP_{16,2}^{riu2}$, $LBP_{24,3}^{riu2}$) e uniforme e não invariante ($LBP_{8,1}^{u2}$, $LBP_{16,2}^{u2}$, $LBP_{24,3}^{u2}$) foram utilizadas para extrair as características das imagens originais e subimagens (patches). De cada configuração, foram obtidos histogramas de ocorrências de padrões de textura, que foram normalizados utilizando a padronização Z-score, que consiste em garantir que a média e o desvio padrão sejam iguais a 0 e 1, respectivamente (Eq. 2).

$$z = \frac{x_i - \mu}{\sigma} \quad Eq. (02)$$

Em que: z é o valor z-score (valor transformado); x_i é o valor do pixel; μ é a média dos valores dos pixels; e σ é o desvio padrão.

Os valores padronizados foram utilizados como entrada para os algoritmos de aprendizado de máquina, de maneira individual, e combinada, a partir da concatenação de vetores de diferentes configurações (por exemplo, $LBP_{8,1}^{u2} + LBP_{16,2}^{u2} + LBP_{24,3}^{u2}$), uma abordagem denominada fusão inicial (*early fusion*).

2.5.2. *Aprendizado por transferência (Transfer learning)*

A CNN é uma vertente do aprendizado profundo, que se destaca por sua estrutura de rede neural *feedforward*, incorporando computação convolucional e profundidade em sua arquitetura (Li et al., 2022). Porém, este é um método que demanda grandes bases de dados para o processo de treinamento e, por sua vez, grandes recursos computacionais.

Uma alternativa para redução desses recursos, é a utilização de redes pré-treinadas, que são adaptadas para a realização da tarefa desejada, sendo, desta forma, uma abordagem conhecida como aprendizagem por transferência (*Transfer Learning*). Essa abordagem é baseada na aplicação do conhecimento aprendido no processo de treinamento, de um determinado problema para outro diferente, porém, semelhante (Huang et al., 2019; Kaya et al., 2019).

Neste estudo, quatro tipos de CNNs pré-treinadas foram utilizadas no processo de extração de características: ResNet50, VGG16, InceptionV3 e MobileNetV2. Essas redes, foram selecionadas com base em uma análise prévia da literatura, que as utilizaram para

tarefas semelhantes de classificação de plantas, obtendo resultados acurados (Cai et al., 2022; Figueroa-Mata et al., 2022b; Zhang et al., 2022).

A ResNet50 é uma arquitetura de CNN que faz parte da família das redes residuais (ResNet). Possuindo 50 camadas, essa rede foi treinada em mais de um milhão de imagens do banco de dados ImageNet (uma coleção de imagens contendo, animais, plantas, objetos, dentre outros), sendo capaz de classificar imagens em até 1000 categorias (Taslim et al., 2021). A VGG16 é uma CNN com 13 camadas de convolução, 5 camadas máximas de pool e 3 camadas densas que somam 21, mas apenas 16 camadas de peso são treináveis (Soni et al., 2023). Essa rede foi criada pelo Grupo de Geometria Visual (*Visual Geometry Group* - VGG) da Universidade de Oxford, sendo empregada com sucesso em diversos problemas de visão computacional.

A rede InceptionV3, engloba cerca de 48 camadas, as quais abrangem não apenas convoluções, mas também diferentes tamanhos de kernels e técnicas de pooling, possibilitando uma utilização mais eficiente dos recursos computacionais disponíveis (Kini et al., 2024). Finalmente, a rede MobileNetV2 é uma arquitetura de CNN com aproximadamente 53 camadas, projetada para alcançar um equilíbrio entre eficiência computacional e desempenho em tarefas de visão computacional, com boa funcionalidade em dispositivos móveis (Faisal et al., 2023).

As quatro CNNs pré-treinadas foram inicializadas com os pesos do ImageNet. A camada final de classificação foi removida e substituída por uma camada de Global Average Pooling (GAP), constituindo o extrator de características. A principal vantagem da GAP é sua capacidade de reduzir a dimensionalidade do mapa de características e o número de parâmetros sem uma perda significativa de informações, ao mesmo tempo que minimiza o risco de overfitting. As imagens foram pré-processadas conforme o padrão especificado para cada uma das redes, e o vetor resultante foi utilizado como entrada para os algoritmos de classificação.

2.6. Algoritmos, validação cruzada e métricas de desempenho

2.6.1. Algoritmos de classificação

Quatro algoritmos de aprendizado de máquina foram utilizados neste estudo: 1) Support Vector Machine (SVM); 2) Artificial Neural Networks (ANN); 3) Random Forest (RF); e 4) Linear Discriminant Analysis (LDA).

O SVM é um método de aprendizado de máquina supervisionado que é utilizado para classificação estatística e análise de regressão (Thirumala et al., 2019). Este método

coloca os recursos obtidos dos dados em um novo plano de coordenadas, e estabelece uma área de limite que divide o conjunto de dados em duas classes durante o processo de treinamento (Toğaçar et al., 2020). Quando se tem problemas de múltiplas classes, a tarefa pode ser convertida em vários problemas de classificação binária (Dourado Filho and Calumby, 2022).

As ANNs, são técnicas que buscam simular o processamento de informação do cérebro humano, fornecendo uma abordagem particular para o desenvolvimento de modelos de regressão e de classificação (Nunes and Görgens, 2016), sendo diferenciadas de outras técnicas de inteligência artificial pela sua arquitetura e pela forma como suas conexões são ajustadas no processo de aprendizagem. Já o algoritmo Random Forest (RF) é uma técnica de aprendizagem em conjunto amplamente adotada para problemas de classificação e regressão (Fan et al., 2021). A solução desse algoritmo é obtida pela média dos valores de saída de várias árvores de decisão (Sahu and Pandey, 2023).

A LDA é um algoritmo de aprendizado supervisionado usado para a classificação de padrões, mas que também é frequentemente usado como técnica de redução de dimensionalidade. Este algoritmo busca encontrar uma combinação linear de características para separar eficientemente múltiplas classes de dados, visando projetar os dados em um espaço de menor dimensionalidade ao maximizar a razão entre a variância entre as classes e a variância dentro das classes (Rosa et al., 2023; Wu et al., 2024).

2.6.2. *Divisão e imagens e validação cruzada*

Inicialmente, a base de imagens de cascas ($n = 2.803$) foi dividida em conjunto de treinamento (80%; $n = 2.237$) e conjunto de teste (20%; $n = 566$), com estratificação em função das classes, garantindo uma divisão balanceada, ou seja, a mesma proporção de imagens por classe nas duas divisões. Esta divisão foi realizada com auxílio da biblioteca *splitfolders* (versão 0.5.1), implementada em linguagem de programação Python. Após a divisão da base de imagens original, foi formado o conjunto de subimagens (256×256 pixels), obtendo-se um conjunto de treinamento (80%; $n = 111.850$) e teste (20%; $n = 28.300$), 50 vezes maior.

No treinamento de cada classificador, a estratégia de pesquisa aleatória (Random Search) foi usada para encontrar os hiperparâmetros de ajuste ótimos. Para tanto, uma grade de hiperparâmetros candidatos foi estabelecida, e o ajuste foi realizado usando validação cruzada de 5 dobras (5-fold Cross Validation) sobre o conjunto de treinamento,

com auxílio do método *RandomizedSearchCV* da biblioteca *scikit-learn*. Na tabela 2 estão os hiperparâmetros candidatos para cada algoritmo de classificação.

Tabela 2: Hiperparâmetros candidatos para cada algoritmo de aprendizado de máquina.

<i>Algoritmo</i>	<i>Hiperparâmetros Candidatos</i>
<i>Redes Neurais Artificiais</i>	hidden_layer_sizes = (50), (100), (150), (200), (250), (300), (350), (400), (450) e (500) activation = relu e identity solver = adam e lbfgs alpha = uniform(loc = 0.0001, scale = 0.09).rvs(size = 20, random_state = 10) learning_rate = constant, adaptive e invscaling
<i>Máquinas de Vetores de Suporte</i>	C = uniform(loc = 0.1, scale = 10).rvs(size = 20, random_state = 10) kernel = linear, rbf, poly e sigmoid degree = 2, 3 e 4 gamma = scale e auto + list(np.logspace(-9, 3, 13))
<i>Floresta Aleatória</i>	n_estimators = np.arange(40, 320, 20) max_depth = list(np.arange(10, 100, step=10)) + [None] max_features = list(np.arange(30, 60, 5)) + ['sqrt', "log2"] criterion = gini e entropy min_samples_leaf = np.arange(10, 110, 10) min_samples_split = np.arange(2, 10, 2) bootstrap = True e False
<i>Análise Discriminante Linear</i>	solver = lsqr e eigen tol = 0.0001, 0.0002 e 0.0003

Em que: **hidden_layer_sizes**: número de neurônios em cada camada oculta; **activation**: função de ativação; **solver**: algoritmo de otimização usado para atualizar os pesos da rede durante o treinamento; **alpha**: penalidade ou regularização aplicada aos pesos da rede; **learning_rate**: taxa de aprendizado; **C**: controla a regularização do modelo; **kernel**: tipo de função a ser usado no algoritmo para mapear os dados para um espaço de características de maior dimensionalidade; **degree**: usado apenas para o kernel polinomial definindo o grau do polinômio; **gamma**: utilizado para todos os kernels, exceto linear; **n_estimators**: número de árvores na floresta; **max_depth**: profundidade máxima de cada árvore; **max_features**: número máximo de características; **criterion**: define a função para medir a qualidade da divisão em uma árvore de decisão; **min_samples_leaf**: número mínimo de amostras necessárias para ser uma folha em uma árvore; **min_samples_split**: número mínimo de amostras necessárias para dividir um nó; **bootstrap**: indica se as amostras são amostradas com substituição (True) ou não (False); **tol**: parâmetro de tolerância.

Na validação cruzada, empregou-se o método *StratifiedGroupKFold* da biblioteca *scikit-learn*, visando a obtenção de dobras de validação estratificadas (com manutenção da proporção de imagens por classe) e com grupos não sobrepostos. Assim, com este método conseguiu-se: i) manter a proporção de classes (espécie) nas dobras de validação; e ii) restringir (bloquear) para que imagens de uma mesma amostra (árvore) contidas nas dobras de treinamento (k-1), não fossem incluídas na dobra de retenção k.

Devido ao alto custo computacional, os melhores hiperparâmetros encontrados na pesquisa aleatória usando as imagens com tamanhos originais, foram usados nos ajustes dos modelos de classificação construídos utilizando características de subimagens, porém

usando validação cruzada de 10 dobras (10-fold Cross Validation). Todo o processo, abrangendo a etapa de extração de características, ajuste dos modelos de aprendizado de máquina e obtenção das métricas de desempenho, foi implementado em linguagem de programação Python, utilizando os recursos disponíveis no Google Colaboratory, e pode ser consultado em https://github.com/NatallyCelestino/Bark_Recognition.git.

2.6.3. Métricas de desempenho

A avaliação da capacidade de generalização dos modelos de classificação foi realizada usando as seguintes métricas de desempenho obtidas na validação de cruzada e conjunto de teste: acurácia (Eq. 3), recall (Eq. 4) e f1-score (Eq. 5). Além disso, a matriz de confusão foi examinada para identificar os principais erros de classificação.

- i. Acurácia: representa o número de previsões corretas do modelo;
- ii. Recall ou Sensibilidade: Métrica recomendada quando se tem desbalanceamento de classes. Representa a capacidade do modelo de classificação em prever a classe positiva;

$$Acurácia = \frac{VP + VN}{VP + FP + VN + FN} \quad Eq. (03)$$

$$Recall = \frac{VP}{VP + FN} \quad Eq. (04)$$

- iii. F1 – score: é a média harmônica entre o Recall e a Precisão (que representa a quantidade de observações classificadas corretamente). É considerada uma métrica adequada para problemas com classes desbalanceadas;

$$F1 - score = 2 \times \frac{PRECISÃO \times RECALL}{(PRECISÃO + RECALL)} \quad Eq. (05)$$

3. RESULTADOS

3.1. Caracterização do conjunto de imagens

Foram amostradas 160 árvores, de 16 espécies florestais de valor comercial madeireiro, pertencentes a 16 gêneros e 9 famílias, com 6 espécies pertencendo à Fabaceae. As árvores amostradas apresentaram diâmetro a partir de 30 cm, com poucos espécimes com DAP acima de 120 cm sendo consideradas árvores de porte médio a grande (Figura 8).

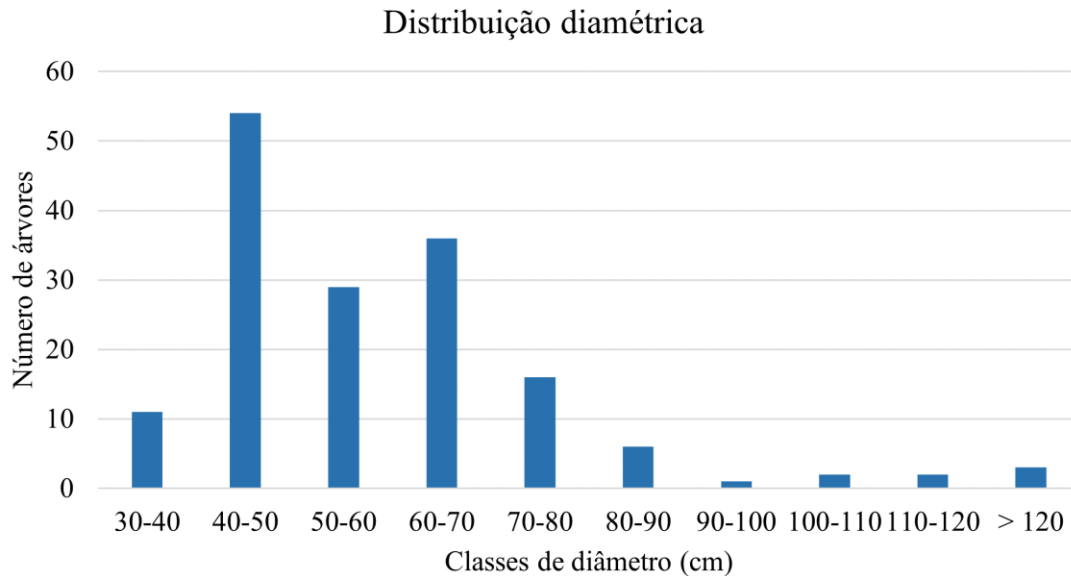


Figura 8: Distribuição diamétrica das árvores-amostra.

3.2. *Desempenho dos classificadores*

Foram ajustados um total de 9 classificadores de imagens de cascas externas de árvores, utilizando o operador LBP como extrator de características, de forma individual e combinada, para cada algoritmo de aprendizado de máquina, usando imagens originais (3024 x 4032 pixels e 4000 x 5328 pixels) e subimagens (256 x 256 pixels).

Na abordagem de extração de características de imagens com tamanhos originais, na maioria dos experimentos, os classificadores construídos usando vetores de características LBP uniforme e não invariante ($LBP_{P,R}^{u2}$) apresentaram melhor desempenho, indicando melhor capacidade em extrair padrões de textura discriminativos de imagens de casca de árvores. Além disso, a combinação de vetores de características extraídas pelos operadores LBP contribuiu, em alguns casos, para alcançar classificadores mais acurados. Os resultados para os ajustes dos modelos usando vetores de características LBP e imagens com tamanhos originais podem ser consultados na tabela 3.

Tabela 3: Desempenho dos classificadores construídos usando características extraídas de imagens originais e os operadores LBP uniforme invariante ($LBP_{P,R}^{riu2}$) e não invariante ($LBP_{P,R}^{u2}$).

Classificador	Tamanho do Vetor	Estatísticas	Validação Cruzada ($k=5, n = 2.237$)								Conjunto de Teste ($n = 566$)							
			SVM		ANN		RF		LDA		SVM		ANN		RF		LDA	
			Acurácia (%)	F1 (%)	Acurácia (%)	F1 (%)	Acurácia (%)	F1 (%)	Acurácia (%)	F1 (%)	Acurácia (%)	F1 (%)	Acurácia (%)	F1 (%)	Acurácia (%)	F1 (%)	Acurácia (%)	F1 (%)
$C1 (LBP_{8,1}^{riu2})$	10	Média	26,14	25,68	31,54	31,11	22,26	21,52	17,58	16,17	38,68	38,48	41,00	40,82	33,00	32,62	20,00	18,82
		dp	1,24	1,40	1,51	1,62	1,39	1,12	2,10	1,84								
$C2 (LBP_{16,2}^{riu2})$	18	Média	32,30	31,16	38,95	38,20	25,47	24,40	22,79	21,54	41,71	40,98	50,00	49,81	34,00	33,63	29,00	27,57
		dp	2,06	2,43	2,26	2,20	0,91	0,77	1,65	1,21								
$C3 (LBP_{24,3}^{riu2})$	26	Média	34,57	34,03	41,58	41,21	26,19	25,14	26,59	25,41	46,88	47,12	52,00	51,44	32,00	31,94	34,00	32,46
		dp	2,60	2,79	2,09	2,04	2,04	1,83	2,01	1,62								
$C4 (LBP_{P,R}^{riu2})$ Todos	54	Média	43,89	43,57	50,23	49,96	28,55	27,00	35,15	34,48	54,55	54,63	60,00	60,60	39,00	37,67	42,00	41,57
		dp	2,97	3,06	1,93	2,05	2,70	2,64	2,35	2,35								
$C5 (LBP_{8,1}^{u2})$	59	Média	38,31	37,96	42,96	42,67	29,21	28,68	31,41	30,81	47,06	47,18	60,00	60,03	41,00	41,38	37,00	37,14
		dp	2,02	1,85	2,19	2,06	1,24	1,40	1,79	1,90								
$C6 (LBP_{16,2}^{u2})$	243	Média	48,75	48,27	52,36	52,04	32,43	31,81	40,81	40,48	62,92	63,09	63,00	63,24	45,00	44,25	51,00	51,16
		dp	1,24	1,55	2,58	2,54	2,32	2,35	2,51	2,86								
$C7 (LBP_{24,3}^{u2})$	555	Média	51,69	50,97	55,17	54,76	33,32	32,35	48,58	48,04	65,60	65,66	66,00	66,13	44,00	43,14	56,00	55,92
		dp	1,30	1,42	2,40	2,53	3,19	3,42	2,91	3,42								
$C8 (LBP_{P,R}^{u2})$ Todos	857	Média	54,73	54,00	60,30	59,90	35,63	34,49	55,40	54,95	67,91	68,10	72,00	72,42	48,00	48,23	64,00	63,79
		dp	1,57	1,78	2,62	2,82	2,96	3,32	3,57	4,07								
$C9 (LBP_{P,R}^{riu2} + LBP_{P,R}^{u2})$ Todos	911	Média	55,40	54,74	60,65	60,26	35,59	34,50	56,25	55,84	68,63	68,79	72,00	71,89	45,00	45,17	65,00	64,91
		dp	2,12	2,26	1,59	1,84	2,96	3,02	4,11	4,61								

Em que: P = número de pontos; R = raio; dp = desvio padrão; SVM = Support Vector Machine; ANN = Artificial Neural Networks; RF = Random Forest; LDA = Linear Discriminant Analysis. O valor em negrito indica o classificador com melhor desempenho

Os classificadores C8 e C9 apresentaram acurácia similar, na validação cruzada e conjunto de teste. Porém, o classificador C8 parece ser mais prático em termos de extração de características de textura, pois depende apenas da combinação das três configurações do operador LBP uniforme e não invariante ($LBP_{8,1}^{u2} + LBP_{16,2}^{u2} + LBP_{24,3}^{u2}$), com menor dimensionalidade de vetores de características. O melhor classificador nesta abordagem (C8), foi desenvolvido com uso de redes neurais multicamadas, cujos hiperparâmetros de ajuste ótimo foram: (hidden layer sizes = (250), activation = identity, solver = lbfgs, alpha = 0,0826, learning rate = constant), com acurácia de 60,30% na validação cruzada e 72% no conjunto de teste.

A abordagem de extração de características de subimagens (patches), combinada com a técnica de voto majoritário, baseado na soma das máximas probabilidades de classes, proporcionou a construção de classificadores mais acurados, na maioria dos experimentos.

Nesta abordagem, o classificador C6, construído com vetores de características de subimagens extraídos pelo operador $LBP_{16,2}^{u2}$ e o algoritmo de redes neurais multicamadas, apresentou desempenho superior na validação cruzada (acurácia = 81,72% e F1 = 81,55%) e conjunto de teste (acurácia = 79% e F1 = 79%) (Tabela 4). Os hiperparâmetros de ajuste ótimo foram: ANN (hidden layer sizes = (500), activation = relu, solver = lbfgs, alpha = 0,0859, learning rate = invscaling). Desta forma, na abordagem com subimagens, foi observado um incremento de 21 pontos percentuais na acurácia da validação cruzada, comparado ao melhor classificador (C8) construído usando imagens de tamanho original.

Tabela 4: Desempenho dos classificadores na validação cruzada e no teste usando as características obtidas através dos operadores LBP uniforme invariante ($LBP_{P,R}^{riu2}$) e não invariante ($LBP_{P,R}^{u2}$), e patches das imagens das cascas das árvores.

Classificador	Tamanho do Vetor	Estatísticas	Validação Cruzada ($k = 10, n = 2,237$)								Conjunto de teste ($n=566$)							
			SVM		ANN		RF		LDA		SVM		ANN		RF		LDA	
			Acurácia (%)	F1 (%)	Acurácia (%)	F1 (%)	Acurácia (%)	F1 (%)	Acurácia (%)	F1 (%)	Acurácia (%)	F1 (%)	Acurácia (%)	F1 (%)	Acurácia (%)	F1 (%)	Acurácia (%)	F1 (%)
C1 ($LBP_{8,1}^{riu2}$)	10	Média	50,03	49,58	47,84	47,22	44,04	43,37	31,12	29,27	47,00	46,00	49,00	48,00	42,00	42,00	31,00	29,00
		dp	2,48	2,66	4,13	4,29	3,60	3,68	2,36	2,19								
C2 ($LBP_{16,2}^{riu2}$)	18	Média	36,17	34,26	52,40	51,39	41,94	40,60	35,18	33,29	37,00	35,00	53,00	53,00	41,00	40,00	36,00	34,00
		dp	3,13	3,47	2,88	2,88	3,86	4,16	4,00	4,03								
C3 ($LBP_{24,3}^{riu2}$)	26	Média	36,88	36,80	56,60	55,85	48,82	47,75	38,81	37,31	30,00	30,00	55,00	55,00	49,00	48,00	39,00	37,00
		dp	1,52	1,52	2,22	2,23	3,01	3,16	3,09	3,05								
C4 ($LBP_{P,R}^{riu2}$) Todos	54	Média	57,84	57,54	72,56	72,36	54,72	54,09	55,43	54,94	56,00	56,00	73,00	73,00	54,00	53,00	53,00	52,00
		dp	2,51	2,63	2,71	2,80	3,80	3,97	3,08	3,19								
C5 ($LBP_{8,1}^{u2}$)	59	Média	66,79	66,51	74,16	73,90	56,95	56,11	53,96	52,87	69,00	69,00	75,00	75,00	56,00	55,00	54,00	53,00
		dp	1,77	1,77	2,66	2,80	2,35	2,43	2,67	2,73								
C6 ($LBP_{16,2}^{u2}$)	243	Média	67,81	67,47	81,72	81,55	59,28	58,56	61,74	61,08	66,00	66,00	79,00	79,00	57,00	55,00	61,00	60,00
		dp	0,63	0,64	3,12	3,19	1,92	2,11	3,89	3,97								
C7 ($LBP_{24,3}^{u2}$)	555	Média	67,90	67,89	78,23	78,07	53,82	52,34	63,21	62,45	67,00	67,00	75,00	75,00	51,00	48,00	61,00	60,00
		dp	2,49	2,50	2,72	2,76	2,67	2,65	3,26	3,31								
C8 ($LBP_{P,R}^{u2}$) Todos	857	Média	77,61	77,29	77,52	77,41	60,22	59,38	73,72	73,46	75,00	74,00	75,00	74,00	60,00	59,00	73,00	72,00
		dp	2,85	2,81	3,16	3,17	2,19	2,29	3,63	3,71								
C9 ($LBP_{P,R}^{riu2} + LBP_{P,R}^{u2}$) Todos	911	Média	77,21	76,9	77,56	77,48	60,93	60,07	73,94	73,66	75,00	75,00	75,00	74,00	60,00	59,00	73,00	72,00
		dp	2,92	2,9	3,28	3,27	2,21	2,27	3,68	3,75								

Em que: P = número de pontos; R = raio; dp = desvio padrão; SVM = Support Vector Machine; ANN = Artificial Neural Networks; RF = Random Forest; LDA = Linear Discriminant Analysis. O valor em negrito indica o classificador com melhor desempenho

A abordagem de usar redes neurais convolucionais pré-treinadas, para extrair características representativas das imagens de casca de árvores, contribuiu para alcançar classificadores mais acurados, comparado ao uso dos operadores LBP. Quando usadas imagens com tamanhos originais, os classificadores construídos usando ResNet50 como extrator de características, e a ANN (hidden layer sizes = (450,), activation = relu, solver = adam, alpha = 0,0695, learning rate = constant) ou SVM (C = 6.9535, kernel = linear) como algoritmos de classificação, apresentaram desempenho similar na validação cruzada e conjunto de teste (Tabela 5).

Tabela 5: Desempenho dos classificadores construídos usando características extraídas de imagens com tamanhos originais e redes neurais convolucionais pré-treinadas.

CNN			Resnet50		VGG16		Inception_V3		MobileNet_V2		
Tamanho do vetor			2048		512		2048		1280		
Estatísticas			Média	dp	Média	dp	Média	dp	Média	dp	
Validação cruzada ($k = 10, n = 2.237$)	SVM	Acurácia (%)	67,36	2,53	56,94	2,32	51,94	1,48	60,30	1,69	
		F1 (%)	66,79	2,73	56,35	2,36	51,36	1,24	59,60	1,39	
	ANN	Acurácia (%)	69,33	0,44	60,39	1,57	52,58	2,43	61,28	1,68	
		F1 (%)	68,73	0,78	59,94	1,44	51,83	2,47	60,60	1,47	
	RF	Acurácia (%)	57,65	2,09	53,47	2,56	45,92	2,28	48,95	2,25	
		F1 (%)	55,74	1,93	50,71	2,53	43,38	2,39	46,29	2,58	
	LDA	Acurácia (%)	63,87	1,79	53,01	1,41	52,22	3,00	59,00	2,10	
		F1 (%)	63,54	1,98	53,08	1,30	52,28	2,54	58,79	1,41	
	Conjunto de Teste ($n = 566$)	SVM	Acurácia (%)	82,69		73,67		63,43		73,32	
			F1 (%)	82,63		73,78		63,25		72,87	
ANN		Acurácia (%)	81,98		74,03		63,25		76,50		
		F1 (%)	82,08		73,98		63,44		76,24		
RF		Acurácia (%)	69,96		59,19		50,53		57,42		
		F1 (%)	69,05		57,53		48,75		56,16		
LDA		Acurácia (%)	77,74		60,42		63,78		71,55		
		F1 (%)	77,83		60,78		64,14		71,62		

Em que: dp = desvio padrão; SVM = Support Vector Machine; ANN = Artificial Neural Networks; RF = Random Forest; LDA = Linear Discriminant Analysis. Os valores em negrito indicam os classificadores com melhores desempenhos.

O classificador construído usando ResNet50 e SVM, obteve um aumento de 7 pontos percentuais na acurácia na validação cruzada, e de aproximadamente 10 pontos percentuais no conjunto de teste, comparado ao classificador C8 ($LBP_{P,R}^{u2}$ e ANN), usando imagens com tamanhos originais.

Já na abordagem usando subimagens, foi observado um incremento de aproximadamente 14 pontos percentuais na acurácia na validação cruzada usando o classificador construído a partir da rede ResNet50 e SVM, comparado aos melhores resultados

obtidos pelos operadores LBP, através do modelo C6 ($LBP_{16,2}^{u2}$ e ANN). Esse classificador alcançou valores de acurácia e F1-score de 95% com desvio padrão inferior a 2%, evidenciando alta capacidade e estabilidade para predizer a classe de novas amostras (Tabela 6).

Tabela 6: Desempenho dos classificadores construídos usando características extraídas de subimagens (patches) e redes neurais convolucionais pré-treinadas.

CNN			ResNet50		VGG16		Inception_V3		MobileNet_V2	
Tamanho do vetor			2048		512		2048		1280	
Estatísticas			Média	dp	Média	dp	Média	dp	Média	dp
Validação cruzada ($k = 10, n = 2,237$)	SVM	Acurácia (%)	95,57	1,07	91,42	1,28	93,21	1,94	94,55	1,53
		F1 (%)	95,57	1,07	91,38	1,27	93,2	1,97	94,53	1,57
	ANN	Acurácia (%)	95,35	1,63	91,28	2,53	91,24	1,45	92,36	1,99
		F1 (%)	95,34	1,64	91,21	2,61	91,18	1,45	92,31	2,01
	RF	Acurácia (%)	84,76	2,83	80,82	3,12	71,71	3,43	76,09	3,04
		F1 (%)	84,48	2,94	80,31	3,40	70,48	3,82	75,15	3,28
	LDA	Acurácia (%)	90,93	2,23	80,33	2,44	84,94	2,21	85,97	2,22
		F1 (%)	91,01	2,24	80,46	2,56	84,87	2,28	85,90	2,22
Conjunto de teste ($n=566$)	SVM	Acurácia (%)	95,00		91,00		92,00		94,00	
		F1 (%)	95,00		91,00		92,00		94,00	
	ANN	Acurácia (%)	94,00		89,00		90,00		91,00	
		F1 (%)	94,00		89,00		90,00		91,00	
	RF	Acurácia (%)	83,00		81,00		67,00		74,00	
		F1 (%)	83,00		80,00		66,00		73,00	
	LDA	Acurácia (%)	92,00		81,00		83,00		86,00	
		F1 (%)	92,00		81,00		83,00		86,00	

Em que: dp = desvio padrão; SVM = Support Vector Machine; ANN = Artificial Neural Networks; RF = Random Forest; LDA = Linear Discriminant Analysis. Os valores em negrito indicam os classificadores com melhores desempenhos.

Nas figuras 9 e 10 estão as matrizes de confusão para os classificadores com melhores desempenhos, construídos a partir de características de subimagens, usando o descritor LBP ($LBP_{16,2}^{u2}$ e ANN – classificador C6) e ResNet50 com SVM, respectivamente. Em relação ao C6, em geral, as espécies *Hymenolobium petraeum*, *Goupia glabra* e *Dipteryx odorata* foram mais confundidas com outras espécies. *Hymenolobium petraeum* foi confundida com várias espécies, em especial, *Astronium lecointei* e *Bowdichia nítida*. *Goupia glabra* foi confundida, sobretudo, com *Dipteryx odorata*, *Hymenolobium petraeum*, *Protium acrense* e *Vatairea sericea*. *Dipteryx odorata* foi mais confundida com *Mezilaurus itauba*. O classificador construído usando ResNet50 e SVM apresentou pouca confusão entre espécies. *Dipteryx odorata* e *Parkia pendula* foram classificadas incorretamente, em especial, como *Apuleia leiocarpa* e *Astronium lecointei*, respectivamente.

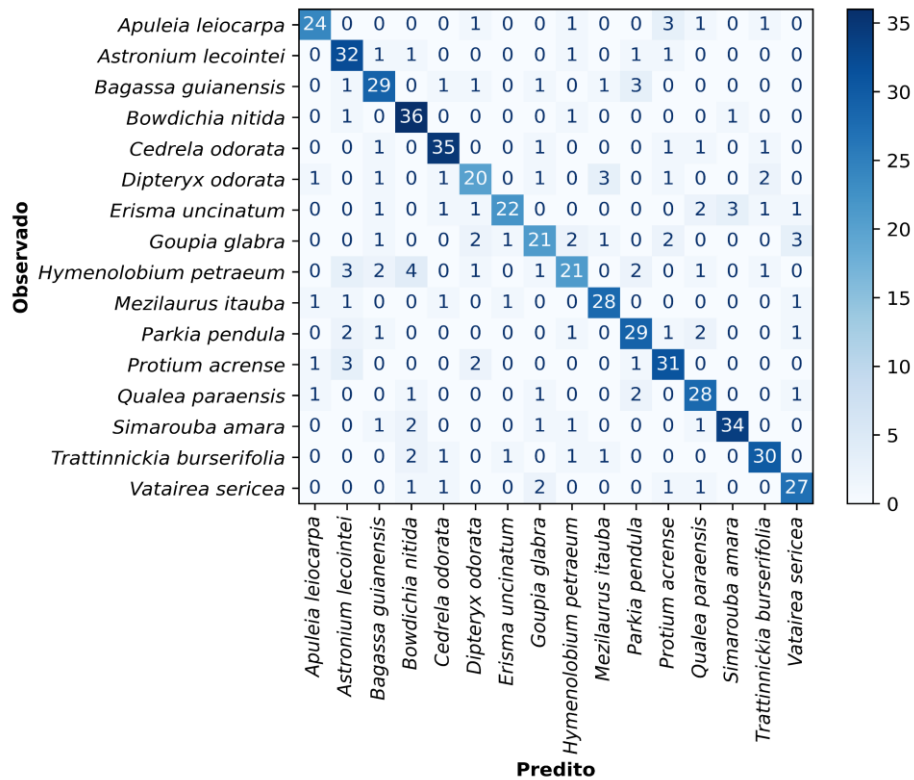


Figura 9: Matriz de confusão no conjunto de teste do classificador C6, construído usando vetores de características de subimagens extraídas pelo operador $LBP_{16,2}^{u2}$ e o algoritmo de rede neural multicamada.




Figura 10: Matriz de confusão no conjunto de teste para o classificador construído usando ResNet50 como extrator de características de subimagens e SVM como algoritmo de classificação.

Na figura 11 está uma comparação do recall por espécie (taxa de verdadeiros positivos por espécie) entre os classificadores C6 ($LBP_{16,2}^{u2}$ e ANN) e ResNet50 com SVM. Em geral, os valores de recall para o classificador C6 foram inferiores, com *Hymenolobium petraeum* e *Goupia glabra* com as menores taxas. Por outro lado, combinar ResNet50 como extrator e SVM como algoritmo de classificação, garantiu maior recall para todas as classes, com taxa de reconhecimento de 100% para 6 espécies.

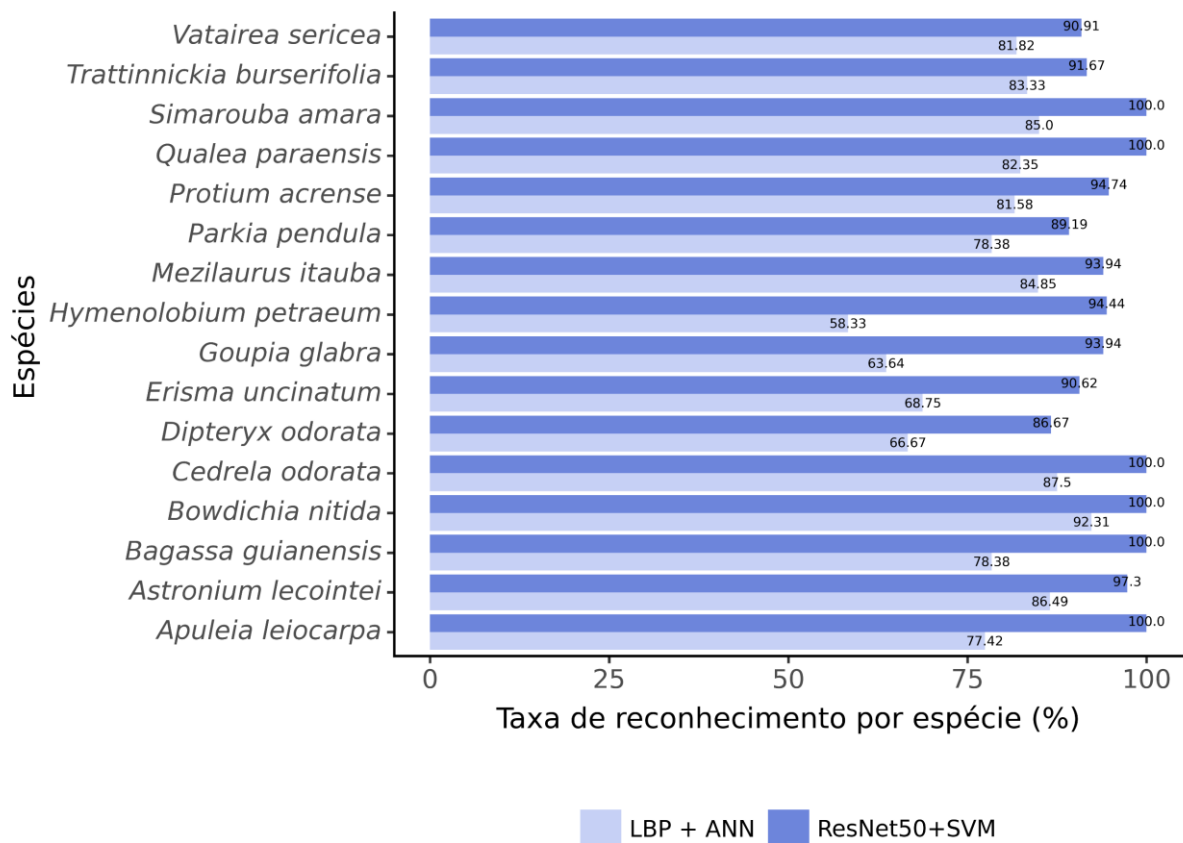


Figura 11: Taxa de reconhecimento por espécie (recall), no conjunto de teste, para os classificadores ($LBP_{16,2}^{u2}$ e ANN – classificador C6) e ResNet50 com SVM, construídos a partir de subimagens.

4. DISCUSSÃO

4.1. Conjunto de imagens: características, fontes de variação e dificuldades

O conjunto de imagens “Amazon Bark” é composto de espécies com altas variações, intra e interespecíficas, nas estruturas morfológicas das cascas externas. Na figura 12 são apresentadas amostras das espécies *Trattinnickia burserifolia* e *Parkia pendula* evidenciando esta variabilidade e, portanto, a complexidade do problema de classificação de espécies da flora Amazônicas. Em campo, foi identificado que as estruturas das cascas externas sofrem forte

influência principalmente do porte da árvore, com variações em função da umidade e do diâmetro, que por sua vez tem forte relação com a idade.




Figura 12: *Trattinnickia burserifolia* (A, B e C) e *Parkia pendula* (D, E e F).

Muitos fatores dificultaram a aquisição de imagens das cascas de árvores. A pouca incidência da luz do solar no interior da floresta foi o principal fator limitante na aquisição de imagens de alta qualidade, sendo necessário o uso de luz artificial. Por outro lado, embora com poucas ocorrências, a incidência direta da luz solar no tronco da árvore também foi prejudicial, pois as imagens apresentavam forte exposição. Aliado a isso, seres vivos como musgos, líquens e cupins foram recorrentes, porém, sempre que possível, foram evitados na aquisição das imagens, visando evidenciar as características das cascas das árvores.

4.2. Padrões Binários Locais

O LBP uniforme e invariante a rotação ($LBP_{P,R}^{riu2}$) é robusto em problemas de classificação cuja orientação dos padrões de textura é uma informação importante. Porém, neste estudo, o LBP uniforme e não invariante ($LBP_{P,R}^{u2}$) foi superior ao operador $LBP_{P,R}^{riu2}$, indicando que a orientação dos padrões de textura não tem forte efeito na discriminação de espécies a partir de imagens de casca de árvores. Outros estudos também reportaram resultados similares em problemas de classificação de espécies arbóreas, porém usando imagens de madeira (Filho et al., 2014; Souza et al., 2020, Rahiddin et al., 2022).

A combinação de descritores (early fusion), que visa melhorar o poder descritivo das imagens e aumentar o desempenho (Tortorici and Werghi, 2017), em geral, garantiu o aprendizado de classificadores mais acurados a partir dos operadores LBP. Por exemplo, ao usar imagens de tamanho original, o operador $LBP_{24,3}^{u2}$ apresentou acurácia de 66%, porém

quando combinados os descritores ($LBP_{8,1}^{u2} + LBP_{16,2}^{u2} + LBP_{24,3}^{u2}$) a acurácia aumentou 6% no conjunto de teste.

Alguns estudos reportam um melhor desempenho de descritores LBP ao realizarem diferentes combinações, porém, utilizando imagens de folhas de plantas. Anubha Pearline et al. (2019) combinaram descritores LBP com características Haralick e Momentos de Hu, usando LDA como algoritmo de classificação, alcançando acurácia de 79,77%. Zhang et al. (2023) reportaram acurácia de 99,4%, ao combinar características LBP com outros descritores (Momentos Zernike e de HU, e características de forma) para classificar espécies em diferentes conjuntos de dados.

A aplicação de descritores LBP em subimagens (patches) favoreceu o alcance de modelos de classificação mais acurados. Isto, possivelmente, está associado a redução de dimensionalidade das imagens e a melhor captura de padrões locais discriminativos, aliado ao uso da estratégia de votação majoritária. Em relação à dimensionalidade, Wäldchen and Mäder (2018) afirmam que imagens de altas dimensões possuem extensas informações associadas aos pixels, dificultando a capacidade de aprendizado dos algoritmos.

Além da capacidade do descritor de extrair informações relevantes, a sua combinação com o classificador também constitui uma etapa importante na construção do modelo de reconhecimento. Neste sentido, os melhores desempenhos utilizando características LBP, foram obtidos a partir da combinação com os classificadores ANN e SVM. Similar a este estudo, algumas pesquisas têm apontado as ANNs (Fekri-Ershad, 2020, Ariyapadath, 2021, Ghosh and Roy, 2022) e SVMs (Bertrand et al., 2017, Boudra et al., 2022b) como melhores algoritmos para construir classificadores usando descritores LBP. Por exemplo, Fekri-Ershad (2020) aplicaram uma variação aprimorada do descritor LBP para extrair padrões de imagens das cascas e alcançaram acurácia de 86,76%, usando redes neurais artificiais para classificar 12 espécies florestais da Eslovênia.

4.3. *Transferência de aprendizado*

Alguns estudos têm apontado para a eficácia de redes neurais pré-treinadas em problemas de classificação de plantas usando imagens de diversas estruturas, como folhas (ex.: Vizcarra et al. 2021; Zhang et al., 2022), madeira (ex.: Ravindran et al., 2018; Yang et al., 2021; Figueroa-Mata et al., 2022; He et al., 2022), casca (ex.: Carpentier et al., 2018, Kim et al., 2022) e carvão (ex.: Maruyama et al., 2018, Menon et al., 2019). Apesar disso, pesquisas usando imagens de cascas de árvores e aprendizado profundo ainda são incipientes (Cui et al., 2023),

o que pode estar relacionado a complexidade do problema de aprendizado e ao limitado número de conjuntos de dados com imagens suficientes para realizar a classificação.

Uma argumentação aceita é de que conjunto de dados maiores favorecem a construção de modelos de aprendizado profundo mais acurados (Khosla and Saini, 2020), além de reduzir o risco de overfitting (Nanni et al., 2021). Neste estudo, a abordagem de extrair subimagens de baixa resolução (256 x 256 pixels) a partir de imagens de tamanho original garantiu aumento da acurácia dos classificadores, independente da rede pré-treinada e do algoritmo de classificação. Portanto, a melhora está associada, possivelmente, ao aumento da dimensionalidade do conjunto de treinamento, aliado ao uso de imagens de baixa resolução.

A estratégia de extração de subimagens a partir de imagens de alta resolução, combinada com aprendizado profundo e voto majoritário, foi reportada como eficaz na classificação de espécies florestais baseadas em imagens de carvão (Maruyama et al., 2018) e madeira (Fabijańska et al., 2021). Maruyama et al. (2018) usando imagens de carvão de 44 espécies florestais (n = 528 imagens) encontraram acurácia de 95,7%, e Fabijańska et al. (2021) usando imagens de madeira de 14 espécies de árvores europeias (n = 312) alcançaram acurácia de 93%.

Os classificadores com melhores desempenhos, foram obtidos usando ResNet50 como extrator e os algoritmos ANN ou SVM como classificadores. Este resultado é compatível com outros estudos de classificação de imagens de plantas (Durairajah et al., 2018; Diwedi et al., 2024; Zhao et al., 2020). Por exemplo, Diwedi et al. (2024) testaram uma rede ResNet50 como extrator de características de imagens de folhas de 6.500 plantas medicinais indianas, e encontraram acurácia de 96,8%, usando o algoritmo de máquinas de vetores de suporte como classificador.

A maioria dos estudos com imagens de cascas de árvores e aprendizado por transferência usam redes neurais densamente conectadas como classificador padrão e com excelentes resultados (Carpentier et al., 2018; Ido and Saitoh, 2019; Faizal, 2022; Z. Cui et al., 2023). Neste estudo, porém, o algoritmo SVM foi experimentado e garantiu resultados ligeiramente superiores. Por outro lado, é importante destacar a eficiência do algoritmo LDA, que conciliou boa capacidade preditiva e rápido aprendizado de classificadores, o que segundo Sachar e Kumar (2021) é o cenário ideal no contexto de aprendizado dos classificadores. Por exemplo, neste estudo, LDA alcançou acurácia de 92% em aproximadamente duas horas de treinamento, porém, SVM ultrapassou seis horas para alcançar 95% de acurácia, ambos usando recursos de subimagens extraídos por ResNet50.

No âmbito do MFS para fins madeireiros na Amazônia brasileira, esta pesquisa foi um pequeno passo na direção de alcançar um sistema de reconhecimento de espécies da flora

confiável e generalista, baseado em imagens de cascas externas e aprendizado profundo. O classificador construído possui alta acurácia e pode ser usado para reconhecer 16 espécies de valor comercial madeireiro, podendo ser usado para minimizar os erros de identificação de espécies em censos florestais.

4.4. Classificações incorretas

Ao avaliar a qualidade das previsões dos classificadores, através das suas matrizes de confusão, foram identificadas algumas classificações incorretas principalmente usando o operador LBP. Na figura 13 estão quatro imagens do conjunto de teste da espécie *Hymenolobium petraeum* que foram classificadas como *Bowdichia nítida* e *Astronium lecointei*, usando o classificador C6 ($LBP_{16,2}^{u2}$ e ANN) e subimagens.




Figura 13: Imagens da espécie *Hymenolobium petraeum* que foram confundidas com as espécies *Bowdichia nítida* e *Astronium lecointei*, nas previsões do classificador C6 ($LBP_{16,2}^{u2}$ e ANN).

É possível identificar características de texturas semelhantes para as espécies confundidas com *Hymenolobium petraeum*, fato que pode ter contribuído para os erros de classificação. As espécies do gênero *Hymenolobium* são caracterizadas por possuir ritidoma reticulado, com coloração variando de acinzentada para marrom (Ferreira et al., 2004). Estas

características são similares às observadas nas cascas externas de algumas árvores de *Bowdichia nítida*.

Por outro lado, a presença de líquens nas cascas, possivelmente, contribuiu para a confusão entre *Hymenolobium petraeum* e *Astronium lecointei*, pela similaridade nos padrões visuais das manchas. Essas características também foram observadas nas imagens de *Hymenolobium petraeum* e *Dipteryx odorata* que foram erroneamente classificadas como *Apuleia leiocarpa* usando ResNet50 e SVM (Figura 14).

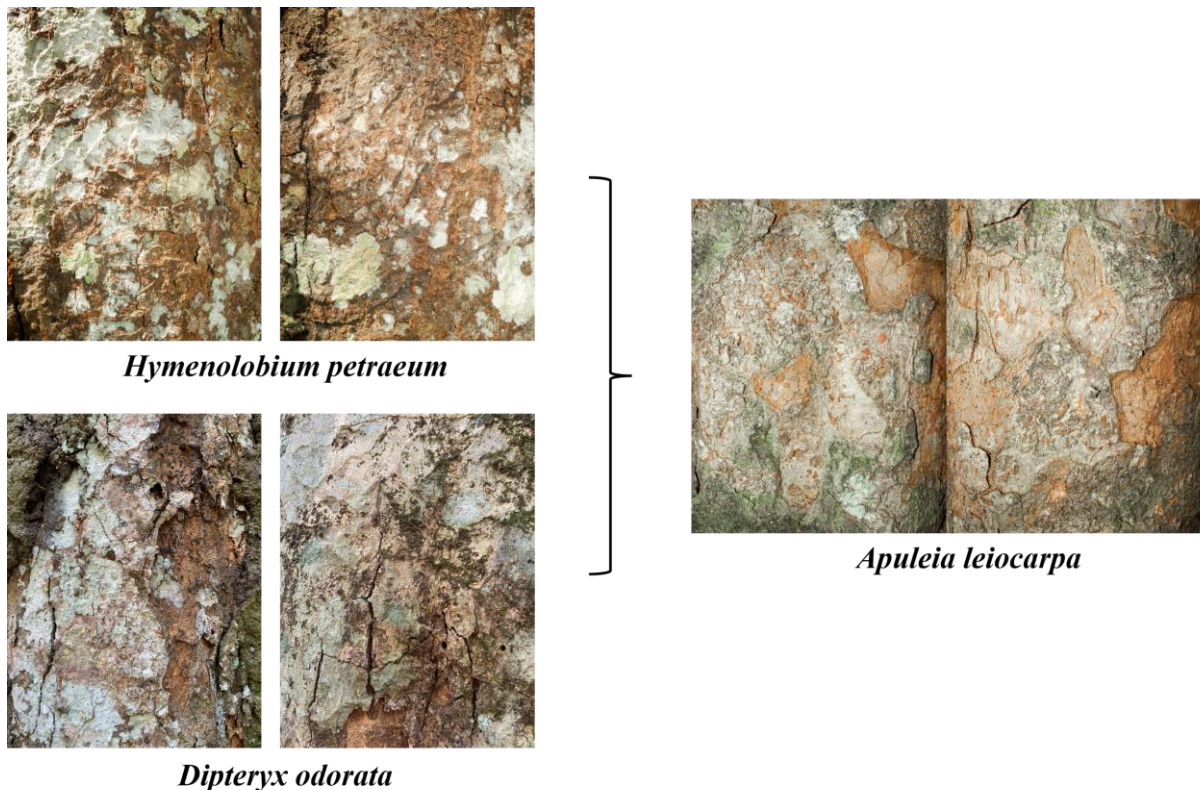


Figura 14: Imagens das espécies *Hymenolobium petraeum* e *Dipteryx odorata* que foram confundidas com a espécie *Apuleia leiocarpa*, nas previsões do classificador construído usando ResNet50 e SVM.

É provável que fatores como condições edafoclimáticas, sítios, tipologia florestal e posição sociológica possam ter influência nas variações das estruturas morfológicas da casca externas de árvores Amazônicas. Portanto, a construção de um sistema mais generalista depende da ampliação do conjunto de imagens, com inclusão de novas espécies e aumento da representatividade de espécimes, atendo-se aos diversos fatores que podem causar variações nas cascas externas das árvores. Uma amostragem que considere a distribuição diamétrica de cada espécie-alvo seria um bom começo, mas não é uma tarefa trivial.

5. CONCLUSÃO

A construção de um sistema de reconhecimento de espécies amazônicas madeireiras, usando imagens de cascas de árvores e aprendizado profundo, mostrou ser uma abordagem eficaz e com grande potencial para aplicações em inventários florestais. Porém, é importante a ampliação da base de imagens, com inclusão de outras espécies de valor madeireiro e aumento das representatividades de espécimes, atendo-se aos fatores que causam variações nas cascas externas das árvores.

A identificação de campo, por profissional qualificado e com coleta botânica, deve ser uma atividade obrigatória em pesquisas direcionadas ao desenvolvimento de sistemas de reconhecimento de espécies da flora, pois assegura a correta rotulagem das imagens e, por conseguinte, a construção de um sistema confiável para uso como ferramenta auxiliar em inventários florestais.

Extraír características ou representações, usando LBP ou CNNs, de subimagens de cascas com menor resolução, assegurou o aprendizado de classificadores mais acurados, independente do algoritmo de classificação. Este fato pode estar associado à menor complexidade de informações nas subimagens e a melhor identificação de padrões locais pelos algoritmos.

O modelo pré-treinado ResNet50 extraiu melhores representações quando subimagens de casca das árvores foram usadas, e combinado com algoritmos de aprendizado de máquina, como máquina de vetores de suporte ou redes neurais artificiais, assegurou o aprendizado de classificadores com acurácia de 95%.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- A Pravin, Dr. C.Deepa, 2022. Piper Plant Classification using Deep CNN Feature Extraction and Hyperparameter Tuned Random Forest Classification. *Transdiscipl. J. Eng. Sci.* 13, 233–258. <https://doi.org/10.22545/2022/00202>.
- Andrade, C.M.S. de, Salman, A.K.D., Gama, M. de M.B., Parmejiani, R.S., Oliveira, L.C. de, Oliveira, T.K. de, Moura, D.C. de S., López, G.F.Z., Azevedo, J.M.A. de, Zaninetti, R.A., Pereira, W.J.P., 2012. Guia de Espécies. *Guia Arbopasto Man. identificação e seleção espécies arbóreas para Sist. silvipastoris* 91–338.
- Anubha Pearline, S., Sathiesh Kumar, V., Harini, S., 2019a. A study on plant recognition using conventional image processing and deep learning approaches. *J. Intell. Fuzzy Syst.* 36, 1997–2004. <https://doi.org/10.3233/JIFS-169911>
- Anubha Pearline, S., Sathiesh Kumar, V., Harini, S., 2019b. A study on plant recognition using conventional image processing and deep learning approaches. *J. Intell. Fuzzy Syst.* 36, 1997–2004. <https://doi.org/10.3233/JIFS-169911>

- Benini, R., Santana, P., Borgo, M., Girão, V., Campos, M., Klein, F., Kummer, O.P., Netto, D.S. de A., Rodrigues, R.R., Nave, A.G., Gandolfi, S., 2016. Manual De Restauração Da Vegetação Nativa, Alto Teles Pires, Mt Expediente 136.
- Bertrand, S., Cerutti, G., Tougne, L., 2017. Bark Recognition to Improve Leaf-based Classification in Didactic Tree Species Identification, in: Proceedings of the 12th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications. SCITEPRESS - Science and Technology Publications, pp. 435–442. <https://doi.org/10.5220/0006108504350442>
- Bisen, D., 2021. Deep convolutional neural network based plant species recognition through features of leaf. *Multimed. Tools Appl.* 80, 6443–6456. <https://doi.org/10.1007/s11042-020-10038-w>
- Borges, H.B.N., Silveira, E.A., Vendramin, L.N., 2014. Flora Arbórea de Mato Grosso - tipologia vegetais e suas espécies.
- Cai, X., Huo, Y., Chen, Y., Xi, M., Tu, Y., Sun, C., Sun, H., 2022. Real-Time Leaf Recognition Method Based on Image Segmentation and Feature Extraction. *Int. J. Pattern Recognit. Artif. Intell.* 36, 1–24. <https://doi.org/10.1142/S0218001421540331>
- Carpentier, M., Giguere, P., Gaudreault, J., 2018a. Tree Species Identification from Bark Images Using Convolutional Neural Networks, in: 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, pp. 1075–1081. <https://doi.org/10.1109/IROS.2018.8593514>
- Carpentier, M., Giguere, P., Gaudreault, J., 2018b. Tree Species Identification from Bark Images Using Convolutional Neural Networks, in: 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, pp. 1075–1081. <https://doi.org/10.1109/IROS.2018.8593514>
- Chen, X., Wang, B., 2020. Invariant leaf image recognition with histogram of Gaussian convolution vectors. *Comput. Electron. Agric.* 178, 105714. <https://doi.org/10.1016/j.compag.2020.105714>
- CONAMA - Conselho Nacional do Meio Ambiente, 2009. Resolução nº 406, 02 de fevereiro de 2009. Ministério do Meio Ambiente. Fevereiro, 2009
- Cysneiros, V. C. et al. (2018). Espécies madeireiras da Amazônia: riqueza, nomes populares e suas peculiaridades. *Pesquisa Florestal Brasileira*, n.38, pg.1-14
- Cui, Z., Li, X., Li, T., Li, M., 2023. Improvement and Assessment of Convolutional Neural Network for Tree Species Identification Based on Bark Characteristics. *Forests* 14, 1292. <https://doi.org/10.3390/f14071292>
- Diwedi, H.K., Misra, A., Tiwari, A.K., 2024. CNN-based medicinal plant identification and classification using optimized SVM, *Multimedia Tools and Applications*. Springer US. <https://doi.org/10.1007/s11042-023-16733-8>
- Dourado Filho, L.A., Calumby, R.T., 2022. Data Augmentation policies and heuristics effects over dataset imbalance for developing plant identification systems based on Deep Learning: A case study. *Rev. Bras. Comput. Apl.* 14, 85–94. <https://doi.org/10.5335/rbca.v14i2.13487>
- Durairajah, V., Gobe, S., Muneer, A., 2018. Automatic Vision Based Classification System Using DNN and SVM Classifiers, in: 2018 3rd International Conference on Control, Robotics and Cybernetics (CRC). IEEE, pp. 6–14. <https://doi.org/10.1109/CRC.2018.00011>

- Encinas, J.I., Antônio, M., Ferreira, C., Riesco, G., Alboreca, A.R., 2022. Introduction Forest management in the sustained yield regime considers that in the management 13. <https://doi.org/10.29298/rmcf.v13i72.1179>
- Engel, J., Brousseau, L., Baraloto, C., 2016. GuiaTreeKey, a multi-access electronic key to identify tree genera in French Guiana. *PhytoKeys* 68, 27–44. <https://doi.org/10.3897/phytokeys.68.8707>
- Fabijańska, A., Danek, M., Barniak, J., 2021. Wood species automatic identification from wood core images with a residual convolutional neural network. *Comput. Electron. Agric.* 181, 105941. <https://doi.org/10.1016/j.compag.2020.105941>
- Faisal, S., Javed, K., Ali, S., Alasiry, A., Marzougui, M., Khan, M.A., Cha, J.H., 2023. Deep Transfer Learning Based Detection and Classification of Citrus Plant Diseases. *Comput. Mater. Contin.* 76, 895–914. <https://doi.org/10.32604/cmc.2023.039781>
- Faizal, S., 2022. Automated Identification of Tree Species by Bark Texture Classification Using Convolutional Neural Networks. *Int. J. Res. Appl. Sci. Eng. Technol.* 10, 1384–1392. <https://doi.org/10.22214/ijraset.2022.46846>
- Fan, G., Yu, M., Dong, S., Yeh, Y., Hong, W., 2021. Forecasting short-term electricity load using hybrid support vector regression with grey catastrophe and random forest modeling. *Util. Policy* 73, 101294. <https://doi.org/10.1016/j.jup.2021.101294>
- Fekri-Ershad, S., 2020. Bark texture classification using improved local ternary patterns and multilayer neural network. *Expert Syst. Appl.* 158, 113509. <https://doi.org/10.1016/j.eswa.2020.113509>
- Ferreira, R. L. A.; Cerqueira, R. M.; Junior, R. C. (2020). Análise da identificação botânica em inventários florestais de planos de manejo sustentáveis no oeste paraense. *Nature and Conservation*, v.13, n.3, p.136-145, 2020.
- Ferreira, G.C., Hopkins, M.J.G., Secco, R. de S., 2004. Contribuição ao conhecimento morfológico das espécies de leguminosae comercializadas no estado do Pará, como “angelim.” *Acta Amaz.* 34, 219–232. <https://doi.org/10.1590/s0044-59672004000200010>
- Figueroa-Mata, G., Mata-Montero, E., Valverde-Otárola, J.C., Arias-Aguilar, D., Zamora-Villalobos, N., 2022. Using Deep Learning to Identify Costa Rican Native Tree Species From Wood Cut Images. *Front. Plant Sci.* 13, 1–12. <https://doi.org/10.3389/fpls.2022.789227>
- Geus, A.R. de, Backes, A.R., Gontijo, A.B., Albuquerque, G.H.Q., Souza, J.R., 2021. Amazon wood species classification: a comparison between deep learning and pre-designed features. *Wood Sci. Technol.* 55, 857–872. <https://doi.org/10.1007/s00226-021-01282-w>
- Ghosh, A., Roy, P., 2022. An automated model for leaf image-based plant recognition: an optimal feature-based machine learning approach. *Innov. Syst. Softw. Eng.* <https://doi.org/10.1007/s11334-022-00440-y>
- Gogul, I., Kumar, V.S., 2017. Flower species recognition system using convolution neural networks and transfer learning, in: 2017 Fourth International Conference on Signal Processing, Communication and Networking (ICSCN). IEEE, pp. 1–6. <https://doi.org/10.1109/ICSCN.2017.8085675>
- Hadlich, H.L., Durgante, F.M., Santos, J., Higuchi, N., Chambers, Q., Vicentini, A., 2018. Forest Ecology and Management Recognizing Amazonian tree species in the field using bark tissues spectra 427, 296–304. <https://doi.org/10.1016/j.foreco.2018.06.002>

- He, J., Sun, Y., Yu, C., Cao, Y., Zhao, Y., Du, G., 2022. An Improved Wood Recognition Method Based on the One-Class Algorithm. *Forests* 13, 1350. <https://doi.org/10.3390/f13091350>
- Huang, Z., He, C., Wang, Z.-N., Xi, J., Wang, H., Hou, L., 2019. Cinnamomum Camphora Classification Based on Leaf Image Using Transfer Learning, in: 2019 IEEE 4th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC). IEEE, pp. 1426–1429. <https://doi.org/10.1109/IAEAC47372.2019.8997791>
- Huixian, J., 2020. The Analysis of Plants Image Recognition Based on Deep Learning and Artificial Neural Network. *IEEE Access* 8, 68828–68841. <https://doi.org/10.1109/ACCESS.2020.2986946>
- Ido, J., Saitoh, T., 2019. CNN-based tree species identification from bark image, in: Yu, H., Pu, Y., Li, C., Pan, Z. (Eds.), Tenth International Conference on Graphics and Image Processing (ICGIP 2018). SPIE, p. 63. <https://doi.org/10.1117/12.2524213>
- Instituto Brasileiro de Geografia e Estatística – IBGE. *Prod. Extr. veg. e Silvíc.*, Rio de Janeiro, v. 35, p. 1-8, 2021
- Kaya, A., Keceli, A.S., Catal, C., Yalic, H.Y., Temucin, H., Tekinerdogan, B., 2019. Analysis of transfer learning for deep neural network based plant classification models. *Comput. Electron. Agric.* 158, 20–29. <https://doi.org/10.1016/j.compag.2019.01.041>
- Keivani, M., Mazloum, J., Sedaghatfar, E., Tavakoli, M.B., 2020. Automated analysis of leaf shape, texture, and color features for plant classification. *Trait. du Signal* 37, 17–28. <https://doi.org/10.18280/ts.370103>
- Khosla, C., Saini, B.S., 2020. Enhancing Performance of Deep Learning Models with different Data Augmentation Techniques : A Survey. <https://doi.org/10.1109/ICIEM48762.2020.9160048>
- Kini, A.S., Prema, K. V., Pai, S.N., 2024. Early stage black pepper leaf disease prediction based on transfer learning using ConvNets. *Sci. Rep.* 14, 1404. <https://doi.org/10.1038/s41598-024-51884-0>
- Kumar, M., Gupta, S., Gao, X.-Z., Singh, A., 2019. Plant Species Recognition Using Morphological Features and Adaptive Boosting Methodology. *IEEE Access* 7, 163912–163918. <https://doi.org/10.1109/ACCESS.2019.2952176>
- Lang, C., Almeida, D.R.A., Costa, F.R.C., 2017. Forest Ecology and Management Discrimination of taxonomic identity at species , genus and family levels using Fourier Transformed Near-Infrared Spectroscopy (FT-NIR). *For. Ecol. Manage.* 406, 219–227. <https://doi.org/10.1016/j.foreco.2017.09.003>
- Li, J., Sun, S., Jiang, H., Tian, Y., Xu, X., 2022. Image recognition and empirical application of desert plant species based on convolutional neural network. *J. Arid Land* 14, 1440–1455. <https://doi.org/10.1007/s40333-022-0086-9>
- Loyola, R., Machado, N., Nova, D.V., Martins, E., Martinelli, G., 2014. Áreas prioritárias para conservação e uso sustentável da flora brasileira ameaçada de extinção.
- Maruyama, T.M., Oliveira, L.S., Britto, A.S., Nisgoski, S., 2018. Automatic classification of native wood charcoal. *Ecol. Inform.* 46, 1–7. <https://doi.org/10.1016/j.ecoinf.2018.05.008>
- Melo, R.R. de, Rocha, M.J., Rodolfo Junior, F., Stangerlin, D.M., 2017. Análise da influência do diâmetro no rendimento em madeira serrada de cambará (*Qualea* sp.). *Pesqui. Florest. Bras.* 36, 393. <https://doi.org/10.4336/2016.pfb.36.88.1151>

- Menezes, M., Bicudo, C.E.M., Moura, C.W.N., Alves, A.M., Santos, A.A., Pedrini, A. de G., Araújo, A., Tucci, A., Fajar, A., Malone, C., Kano, C.H., Sant'Anna, C.L., Branco, C.Z., Odebrecht, C., Peres, C.K., Neuhaus, E.B., Eskinazi-Leça, E., Aquino, E., Nauer, F., Santos, G.N., Amado Filho, G.M., Lyra, G.M., Borges, G.C.P., Costa, I.O., Nogueira, I. de S., Oliveira, I.B., Paula, J.C. d., Nunes, J.M. de C., Lima, J.C., Santos, K.R.S., Ferreira, L.C., Gestinari, L.M.S., Cardoso, L.S., Figueiredo, M.A.O., Silva, M.H., Barreto, M.B.B.B., Henriques, M.C.O., Cunha, M. da G.G.S., Bandeira-Pedrosa, M.E., Oliveira-Carvalho, M.F., Széchy, M.T.M., Azevedo, M.T.P., Oliveira, M.C. de, Cabezudo, M.M., Santiago, M.F., Bergesh, M., Fujii, M.T., Bueno, N.C., Necchi Jr., O., Jesus, P.B., Bahia, R.G., Khader, S., Alves-da-Silva, S.M., Guimarães, S.M.P.B., Pereira, S.M.B., Caires, T.A., Meurer, T., Cassano, V., Werner, V.R., Gama Jr., W.A. da, Silva, W.J. da, 2015. Update of the Brazilian floristic list of Algae and Cyanobacteria. *Rodriguésia* 66, 1047–1062. <https://doi.org/10.1590/2175-7860201566408>
- Menon, L.T., Laurensi, I.A., Penna, M.C., Oliveira, L.E.S., Britto, A.S., 2019. Data Augmentation and Transfer Learning Applied to Charcoal Image Classification, in: 2019 International Conference on Systems, Signals and Image Processing (IWSSIP). IEEE, pp. 69–74. <https://doi.org/10.1109/IWSSIP.2019.8787271>
- Misra, D., Crispim-Junior, C., Tougne, L., 2020. Patch-Based CNN Evaluation for Bark Classification. pp. 197–212. https://doi.org/10.1007/978-3-030-65414-6_15
- Nanni, L., Paci, M., Brahnem, S., Lumini, A., 2021. Comparison of Different Image Data Augmentation Approaches. *J. Imaging* 7, 254. <https://doi.org/10.3390/jimaging7120254>
- Novaes1, T.V., Ramalho, F.M.G., da Silva Araujo, E., Lima, M.D.R., da Silva, M.G., Ferreira, G.C., Hein, P.R.G., 2023. Discrimination of amazonian forest species by NIR spectroscopy: wood surface effects. *Eur. J. Wood Wood Prod.* 81, 159–172. <https://doi.org/10.1007/s00107-022-01862-y>
- Nunes, M.H., Görgens, E.B., 2016. Artificial Intelligence Procedures for Tree Taper Estimation within a Complex Vegetation Mosaic in Brazil. *PLoS One* 11, e0154738. <https://doi.org/10.1371/journal.pone.0154738>
- Ojala, T., Pietikhenl, M., Harwood, D., 1994. Performance Evaluation of Texture Measures with Classification Based on Kullback Discrimination of Distributions 582–585.
- Ojala, T.; Pietikäinen, M. Harwood, D. A comparative study of texture measures with classification based on distribution. *Pattern Recognition*, v. 29, n.1, p.51-59, 1996.
- Ojala, T., Pietikainen, M., & Maenpaa, T. (2002). Multiresolution gray-scale and rotation invariant texture classification with local binary pat-terns. *IEEE Transactions on pattern analysis and machine intelligence*. v. 24(7), p. 971–987.
- Paula Filho, P.L., Luiz, F., Nisgoski, S., Britto, A.S., 2014. Forest species recognition using macroscopic images 1019–1031. <https://doi.org/10.1007/s00138-014-0592-7>
- Procópio, L.C., Secco, R.D.S., 2008. A importância da identificação botânica nos inventários florestais: o exemplo do “tauari” (*Couratari* spp. e *Cariniana* spp. - *Lecythidaceae*) em duas áreas manejadas no estado do Pará. *Acta Amaz.* 38, 31–44. <https://doi.org/10.1590/S0044-59672008000100005>
- Rahiddin, R.N.N., Hashim, U.R., Salahuddin, L., Kanchymalay, K., Wibawa, A.P., Chun, T.H., 2022. Local Texture Representation for Timber Defect Recognition based on Variation of LBP. *Int. J. Adv. Comput. Sci. Appl.* 13, 443–448. <https://doi.org/10.14569/IJACSA.2022.0131053>

- Ran, J., Shi, Y., Yu, J., Li, D., 2021. A Multi-Feature Convolution Neural Network for Automatic Flower Recognition. *J. Circuits, Syst. Comput.* 30, 1–15. <https://doi.org/10.1142/S0218126621502819>
- Remeš, V., Haindl, M., 2019. Bark recognition using novel rotationally invariant multispectral textural features. *Pattern Recognit. Lett.* 125, 612–617. <https://doi.org/10.1016/j.patrec.2019.06.027>
- Robert, M., Dallaire, P., Giguere, P., 2020. Tree bark re-identification using a deep-learning feature descriptor. *Proc. - 2020 17th Conf. Comput. Robot Vision, CRV 2020* 25–32. <https://doi.org/10.1109/CRV50864.2020.00012>
- Rosa, A.C.F. da, Galdamez, E.V.C., Souza, R.C.T. de, Melo, M. das G.M., Villarinho, A.L.C.F., Leal, G.C.L., 2023. Uso de técnicas de aprendizado de máquina para classificação de fatores que influenciam a ocorrência de dermatites ocupacionais. *Rev. Bras. Saúde Ocup.* 48, 1–10. <https://doi.org/10.1590/2317-6369/31620pt2023v48e4>
- Sachar, S., Kumar, A., 2021. Survey of feature extraction and classification techniques to identify plant through leaves. *Expert Syst. Appl.* 167, 114181. <https://doi.org/10.1016/j.eswa.2020.114181>
- Sahu, S.K., Pandey, M., 2023. An optimal hybrid multiclass SVM for plant leaf disease detection using spatial Fuzzy C-Means model. *Expert Syst. Appl.* 214, 118989. <https://doi.org/10.1016/j.eswa.2022.118989>
- Silveira, A.B. da, Santos, J. de P. dos, Rebellato, L., 2017. Guia de boas práticas: Restauração de Áreas de Preservação Permanente Degradadas (APPDs), Experiência da Fazenda São Nicolau.
- Soni, P., Dhavale, S., Yenishetti, S., Panat, L., Karajkhede, G., 2023. Medicinal Plant Species Identification Using AI, in: 2023 IEEE 11th Region 10 Humanitarian Technology Conference (R10-HTC). IEEE, pp. 662–668. <https://doi.org/10.1109/R10-HTC57504.2023.10461734>
- Souza, D.V., Santos, J.X., Vieira, H.C., Naide, T.L., Nisgoski, S., Oliveira, L.E.S., 2020. An automatic recognition system of Brazilian flora species based on textural features of macroscopic images of wood. *Wood Sci. Technol.* 54, 1065–1090. <https://doi.org/10.1007/s00226-020-01196-z>
- Stragliotto, M.C., Pereira, B.L.C., Oliveira, A.C., 2020. Indústrias Madeireiras E Rendimento Em Madeira Serrada Na Amazônia Brasileira. *Eng. Florest. Desafios, Limites e Potencialidade* 499–518. <https://doi.org/10.37885/200801030>
- Taslim, A., Saon, S., Mahamad, A.K., Muladi, M., Hidayat, W.N., 2021. Plant leaf identification system using convolutional neural network. *Bull. Electr. Eng. Informatics* 10, 3341–3352. <https://doi.org/10.11591/eei.v10i6.2332>
- Thanikkal, J.G., Dubey, A.K., Thomas, M.T., 2023. An Efficient Mobile Application for Identification of Immunity Boosting Medicinal Plants using Shape Descriptor Algorithm. *Wirel. Pers. Commun.* 131, 1189–1205. <https://doi.org/10.1007/s11277-023-10476-3>
- The Brazil Flora Group, B., 2021. Flora do Brasil 2020. *Jard. Botânico do Rio Janeiro* <http://floradobrasil.jbrj.gov.br/Access> 19 Set 2. <https://doi.org/10.47871/jbrj2021001>
- Thirumala, K., Pal, S., Jain, T., Umarikar, A.C., 2019. Neurocomputing A classification method for multiple power quality disturbances using EWT based adaptive filtering and multiclass SVM. *Neurocomputing* 334, 265–274. <https://doi.org/10.1016/j.neucom.2019.01.038>

- Toğaçar, M., Ergen, B., Cömert, Z., 2020. Classification of flower species by using features extracted from the intersection of feature selection methods in convolutional neural network models. *Measurement* 158, 107703. <https://doi.org/10.1016/j.measurement.2020.107703>
- Tortorici, C., Werghe, N., 2017. Early Features Fusion over 3D Face for Face Recognition, in: Ben Amor, B., Chaieb, F., Ghorbel, F. (Eds.), *Communications in Computer and Information Science*. Springer International Publishing, Cham, pp. 56–64. https://doi.org/10.1007/978-3-319-60654-5_5
- Turkoglu, M., Hanbay, D., 2019. Leaf-based plant species recognition based on improved local binary pattern and extreme learning machine. *Phys. A Stat. Mech. its Appl.* 527, 121297. <https://doi.org/10.1016/j.physa.2019.121297>
- Venicio, D., Joielan, S., Santos, X., Cristina, H., Lorena, T., Silvana, N., Luiz, N., Oliveira, E.S., 2020. An automatic recognition system of Brazilian flora species based on textural features of macroscopic images of wood. *Wood Sci. Technol.* 54, 1065–1090. <https://doi.org/10.1007/s00226-020-01196-z>
- Vieira, G.L. de S., Ponte, M.J.M. da, Moutinho, V.H.P., Jardim-Gonçalves, R., Lima, C.P., Albuquerque, V.M.V. de, 2022. Identification of wood from the Amazon by characteristics of Haralick and Neural Network: image segmentation and polishing of the surface. *iForest - Biogeosciences For.* 15, 234–239. <https://doi.org/10.3832/ifor3906-015>
- Villaruz, J.A., 2021. Deep Convolutional Neural Network Feature Extraction for Berry Trees Classification. *J. Adv. Inf. Technol.* 12, 226–233. <https://doi.org/10.12720/jait.12.3.226-233>
- Wäldchen, J., Mäder, P., 2018. Plant Species Identification Using Computer Vision Techniques: A Systematic Literature Review. *Arch. Comput. Methods Eng.* 25, 507–543. <https://doi.org/10.1007/s11831-016-9206-z>
- Wang, B., Li, H., You, J., Chen, X., Yuan, X., Feng, X., 2022. Fusing deep learning features of triplet leaf image patterns to boost soybean cultivar identification. *Comput. Electron. Agric.* 197, 106914. <https://doi.org/10.1016/j.compag.2022.106914>
- Wu, Q., Luo, J., Fang, H., He, D., Liang, T., 2024. Spectral classification analysis of recycling plastics of small household appliances based on infrared spectroscopy. *Vib. Spectrosc.* 130, 103636. <https://doi.org/10.1016/j.vibspec.2023.103636>
- Yang, Y., Wang, H., Jiang, D., Hu, Z., 2021. Surface Detection of Solid Wood Defects Based on SSD Improved with ResNet. *Forests* 12, 1419. <https://doi.org/10.3390/f12101419>
- Zhang, H., Dai, C., Long, K., Wang, Z., 2023. Effective shape features for leaf classification. *J. Electron. Imaging* 32, 1–27. <https://doi.org/10.1117/1.jei.32.6.063009>
- Zhang, R., Zhu, Y., Ge, Z., Mu, H., Qi, D., Ni, H., 2022. Transfer Learning for Leaf Small Dataset Using Improved ResNet50 Network with Mixed Activation Functions. *Forests* 13, 2072. <https://doi.org/10.3390/f13122072>
- Zhao, Y., Gao, X., Hu, J., Chen, Z., 2020. Tree species identification based on the fusion of bark and leaves. *Math. Biosci. Eng.* 17, 4018–4033. <https://doi.org/10.3934/mbe.2020222>

CONCLUSÃO GERAL

O uso de tecnologias, baseadas em técnicas de visão computacional e inteligência artificial para o reconhecimento de plantas, têm avançado nos últimos anos. Apesar de alguns estudos ainda usarem abordagens tradicionais, a principal tendência é a utilização de técnicas de aprendizado profundo, evidenciado pelo expressivo número de publicações abordando Redes Neurais Convolucionais, e suas variações, como o aprendizado por transferência.

A maioria dos estudos usam imagens de folhas e plantas de pequeno porte, no âmbito de áreas médicas, farmacêuticas ou em contextos mais gerais, para identificação de plantas medicinais ou ornamentais. Estes resultados abrem espaço para estudos que utilizem imagens de outras estruturas da planta, como a casca da árvore, em especial para o reconhecimento de árvores de espécies florestais de grande porte.

O uso de padrões binários locais e de aprendizagem profunda, revelou o potencial de técnicas de extração de características ou representações de imagens de casca de árvores no desenvolvimento de classificadores para reconhecimento de espécies florestais amazônicas. Os classificadores construídos usando representações extraídas pela rede pré-treinada ResNet50, em combinação com os algoritmos MVS ou RNA, alcançaram 95% de acurácia.

Os melhores classificadores podem ser usados com êxito para reconhecer 16 espécies de valor madeireiro, no âmbito do MFS para fins madeireiros na Amazônia brasileira. O desenvolvimento de uma aplicação web ou aplicativo móvel é importante para tornar essa tecnologia acessível e, portanto, servir como ferramenta auxiliar para profissionais na tarefa de identificação de espécies da flora, minimizando os erros de identificação e contribuindo para a conservação de espécies.

ANEXO 1

Tabela 7: Dados da identificação botânica das árvores-amostras realizadas pelo Herbário Felisberto Camargo (HFC) da Universidade Federal Rural da Amazônia (UFRA)

FC-UFRA	LOCAL DE COLETA	LATITUDE	LONGITUDE	NOME VULGAR	NOME CIENTÍFICO	FAMÍLIA	COLETOR	Nº AMOSTRA	DATA	DAP	ALTURA COMERCIAL	ALTURA TOTAL
10609	Fazenda Perola- Nova Maringá, MT	12,6936	57,24765	Cedrinho	<i>Erisma uncinatum</i> Warm	Voschysiaceae	Hamada, M.O.S. 01	1	15/07/2023	49,7cm	16,2m	32,0m
10610	Fazenda Perola- Nova Maringá, MT	12,69363	57,24743	Cedrinho	<i>Erisma uncinatum</i> Warm	Voschysiaceae	Hamada, M.O.S. 02	2	15/07/2023	82,3cm	20,5m	37,5m
10611	Fazenda Perola- Nova Maringá, MT	12,694	57,24681	cumaru	<i>Dipteryx odorata</i> (Aubl.) Forsyth f.	Fabaceae	Hamada, M.O.S. 03	3	15/07/2023	67,3cm	19,1m	33,3m
10612	Fazenda Perola- Nova Maringá, MT	12,69393	57,2467	Garapeira	<i>Apuleia leiocarpa</i> (vogel) J.F.Macbr	Fabaceae	Hamada, M.O.S. 04	4	15/07/2023	63,8cm	14,4m	29,1m
10613	Fazenda Perola- Nova Maringá, MT	12,69381	57,246783	Cedrinho	<i>Erisma uncinatum</i> Warm	Voschysiaceae	Hamada, M.O.S. 05	5	15/07/2023	36,00cm	12,2m	26,3m
10614	Fazenda Perola- Nova Maringá, MT	12,6937	57,24676	Cedrinho	<i>Erisma uncinatum</i> Warm	Voschysiaceae	Hamada, M.O.S. 06	6	15/07/2023	71,00cm	18,60m	32,6m
10615	Fazenda Perola- Nova Maringá, MT	12,6937	57,24673	Garapeira	<i>Apuleia leiocarpa</i> (vogel) J.F.Macbr	Fabaceae	Hamada, M.O.S. 07	7	15/07/2023	46,5cm	16,60m	29,00m
10616	Fazenda Perola- Nova Maringá, MT	12,69391	57,24661	Itaúba	<i>Mezilaurus itaúba</i> (Meisn.) Taub. ex Mez	Lauraceae	Hamada, M.O.S. 08	8	15/07/2023	64,10cm	16,00m	29,20m
10617	Fazenda Perola- Nova Maringá, MT	12,69503	57,24658	cumaru	<i>Dipteryx odorata</i> (Aubl.) Forsyth f.	Fabaceae	Hamada, M.O.S. 09	9	15/07/2023	63,2cm	20,70m	34,00m
10618	Fazenda Perola- Nova Maringá, MT	12,6953	57,24665	Itaúba	<i>Mezilaurus itaúba</i> (Meisn.) Taub. ex Mez	Lauraceae	Hamada, M.O.S. 10	10	15/07/2023	71,10cm	15,00m	35,00m
10619	Fazenda Perola- Nova Maringá, MT	12,6959	57,24636	Garapeira	<i>Apuleia leiocarpa</i> (vogel) J.F.Macbr	Fabaceae	Hamada, M.O.S. 11	11	16/07/2023	62,5cm	11,3m	33,50m
10620	Fazenda Perola- Nova Maringá, MT	12,6958	57,24645	Itaúba	<i>Mezilaurus itaúba</i> (Meisn.) Taub. ex Mez	Lauraceae	Hamada, M.O.S. 12	12	16/07/2023	61,4cm	16,6m	29,6m
10621	Fazenda Perola- Nova Maringá, MT	12,69693	57,24626	Cedrinho	<i>Erisma uncinatum</i> Warm	Voschysiaceae	Hamada, M.O.S. 13	13	16/07/2023	53,5cm	11,4m	26,00m
10622	Fazenda Perola- Nova Maringá, MT	12,6976	57,24608	Itaúba	<i>Mezilaurus itaúba</i> (Meisn.) Taub. ex Mez	Lauraceae	Hamada, M.O.S. 14	14	16/07/2023	57,10cm	14,8m	36,5m
10623	Fazenda Perola- Nova Maringá, MT	12,69798	57,24605	Itaúba	<i>Mezilaurus itaúba</i> (Meisn.) Taub. ex Mez	Lauraceae	Hamada, M.O.S. 15	15	16/07/2023	35,3cm	12,4m	23,7m
10625	Fazenda Perola- Nova Maringá, MT	12,6992	57,24556	cumaru	<i>Dipteryx odorata</i> (Aubl.) Forsyth f.	Fabaceae	Hamada, M.O.S. 17	17	16/07/2023	76,3cm	17,20m	28,20m
10626	Fazenda Perola- Nova Maringá, MT	12,69886	57,24586	Itaúba	<i>Mezilaurus itaúba</i> (Meisn.) Taub. ex Mez	Lauraceae	Hamada, M.O.S. 19	19	16/07/2023	52,5cm	17,50m	29,00m
10627	Fazenda Perola- Nova Maringá, MT	12,69785	57,24638	Garapeira	<i>Apuleia leiocarpa</i> (vogel) J.F.Macbr	Fabaceae	Hamada, M.O.S. 21	21	16/07/2023	43,5cm	8,10m	22,00m
10628	Fazenda Perola- Nova Maringá, MT	12,69845	57,246538	Garapeira	<i>Apuleia leiocarpa</i> (vogel) J.F.Macbr	Fabaceae	Hamada, M.O.S. 24	24	16/07/2023	64,00cm	17,00m	29,10m
10629	Fazenda Perola- Nova Maringá, MT	12,69096	57,24456	cumaru	<i>Dipteryx odorata</i> (Aubl.) Forsyth f.	Fabaceae	Hamada, M.O.S. 32	32	17/07/2023	66,7cm	10,00m	24,60m
10630	Fazenda Perola- Nova Maringá, MT	12,70273	57,24455	cumaru	<i>Dipteryx odorata</i> (Aubl.) Forsyth f.	Fabaceae	Hamada, M.O.S. 33	33	17/07/2023	70,00cm	9,50m	31,00m
10631	Fazenda Perola- Nova Maringá, MT	12,70185	57,2447	Cambará	<i>Qualea paraensis</i> Ducke	Voschysiaceae	Hamada, M.O.S. 38	38	18/07/2023	47,50cm	18,10m	21,30m
10632	Fazenda Perola- Nova Maringá, MT			Cambará	<i>Qualea paraensis</i> Ducke	Voschysiaceae	Hamada, M.O.S. 39	39	18/07/2023	70,50cm	17,10m	34,50m

10633	Fazenda Perola- Nova Maringá, MT	12,68616	57,22773	Cambará	Qualea paraensis Ducke	Voschysiaceae	Hamada, M.O.S. 43	43	18/07/2023	49,80cm	14,80m	28,40m
10634	Fazenda Perola- Nova Maringá, MT	12,68623	57,22775	Cambará	Qualea paraensis Ducke	Voschysiaceae	Hamada, M.O.S. 44	44	18/07/2023	64,30cm	14,40m	27,30m
10635	Fazenda Perola- Nova Maringá, MT	12,68625	57,22785	Cambará	Qualea paraensis Ducke	Voschysiaceae	Hamada, M.O.S. 45	45	18/07/2023	68,80cm	10,00m	27,40m
10637	Fazenda Perola- Nova Maringá, MT	12,69278	57,2477	Angelim amargoso	Vatairea sericea (ducke) Ducke	Fabaceae	Hamada, M.O.S. 55	55	19/07/2023	49,00cm	17,50m	28,00m
10638	Fazenda Perola- Nova Maringá, MT	12,69168	57,24819	Angelim amargoso	Vatairea sericea (ducke) Ducke	Fabaceae	Hamada, M.O.S. 56	56	19/07/2023	48,90cm	9,00m	22,30m
10639	Fazenda Perola- Nova Maringá, MT	12,69115	57,24829	Angelim amargoso	Vatairea sericea (ducke) Ducke	Fabaceae	Hamada, M.O.S. 57	57	19/07/2023	33,90cm	15,00m	23,10m
10640	Fazenda Perola- Nova Maringá, MT	12,68633	57,22786	Angelim amargoso	Vatairea sericea (ducke) Ducke	Fabaceae	Hamada, M.O.S. 58	58	19/07/2023	41,20cm	13,60m	26,70m
10641	Fazenda Perola- Nova Maringá, MT	12,68592	57,22866	Angelim amargoso	Vatairea sericea (ducke) Ducke	Fabaceae	Hamada, M.O.S. 59	59	19/07/2023	35,50cm	15,60m	26,00m
10642	Fazenda Boa esperança- Feliz Natal, MT	12,35677	54,81607	Angelim pedra	Hymenolobium petraeum Ducke	Fabaceae	Hamada, M.O.S. 63	63	21/07/2023	92,00cm	18,10m	35,00m
10643	Fazenda Boa esperança- Feliz Natal, MT	12,35631	54,81554	Cupiúba	Goupia glabra Aubl.	Goupiaceae	Hamada, M.O.S. 64	64	21/07/2023	89,70cm	6,4m	29,70m
10644	Fazenda Boa esperança- Feliz Natal, MT	12,35609	54,81603	Cupiúba	Goupia glabra Aubl.	Goupiaceae	Hamada, M.O.S. 65	65	21/07/2023	71,30cm	14,90m	34,00m
10645	Fazenda Boa esperança- Feliz Natal, MT	12,35601	54,81592	Amescla	Trattinnickia burserifolia Mart.	Burseraceae	Hamada, M.O.S. 66	66	21/07/2023	56,20cm	14,60m	29,00m
10646	Fazenda Boa esperança- Feliz Natal, MT	12,35573	54,81627	Angelim pedra	Hymenolobium petraeum Ducke	Fabaceae	Hamada, M.O.S. 67	67	21/07/2023	68,60cm	16,50m	30,30m
10647	Fazenda Boa esperança- Feliz Natal, MT	12,36262	54,81289	Angelim pedra	Hymenolobium petraeum Ducke	Fabaceae	Hamada, M.O.S. 69	69	21/07/2023	81,10cm	21,60m	31,20m
10648	Fazenda Boa esperança- Feliz Natal, MT	12,36322	54,81273	Angelim pedra	Hymenolobium petraeum Ducke	Fabaceae	Hamada, M.O.S. 70	70	21/07/2023	61,20cm	27,40m	14,30m
10649	Fazenda Boa esperança- Feliz Natal, MT	12,36324	54,81263	Angelim saia	Parkia pendula (Willd) Benth. Ex Walp.	Fabaceae	Hamada, M.O.S. 71	71	21/07/2023	56,80cm	9,8m	24,00m
10650	Fazenda Boa esperança- Feliz Natal, MT	12,36265	54,81216	Cupiúba	Goupia glabra Aubl.	Goupiaceae	Hamada, M.O.S. 72	72	21/07/2023	52,80cm	12,00m	29,00m
10651	Fazenda Boa esperança- Feliz Natal, MT	12,35628	54,81379	Amescla	Trattinnickia burserifolia Mart.	Burseraceae	Hamada, M.O.S. 73	73	22/07/2023	52,20cm	16,90m	29,90m
10652	Fazenda Boa esperança- Feliz Natal, MT	12,35644	54,81456	Amescla	Trattinnickia burserifolia Mart.	Burseraceae	Hamada, M.O.S. 74	74	22/07/2023	53,00cm	20,00m	29,90m
10653	Fazenda Boa esperança- Feliz Natal, MT	12,35629	54,81459	Angelim pedra	Hymenolobium petraeum Ducke	Fabaceae	Hamada, M.O.S. 75	75	22/07/2023	43,10cm	16,20m	31,80m
10654	Fazenda Boa esperança- Feliz Natal, MT	12,36194	54,8123	Angelim saia	Parkia pendula (Willd) Benth. Ex Walp.	Fabaceae	Hamada, M.O.S. 76	76	22/07/2023	62,20cm	13,50m	29,40m
10655	Fazenda Boa esperança- Feliz Natal, MT	12,36386	54,81213	Cupiúba	Goupia glabra Aubl.	Goupiaceae	Hamada, M.O.S. 77	77	22/07/2023	67,40cm	16,70m	29,00m
10656	Fazenda Boa esperança- Feliz Natal, MT	12,36437	54,81199	Cupiúba	Goupia glabra Aubl.	Goupiaceae	Hamada, M.O.S. 78	78	22/07/2023	41,50cm	7,00m	27,50m
10657	Fazenda Boa esperança- Feliz Natal, MT	12,36442	54,81253	Amescla	Trattinnickia burserifolia Mart.	Burseraceae	Hamada, M.O.S. 79	79	22/07/2023	42,70cm	18,50m	29,90m
10658	Fazenda Boa esperança- Feliz Natal, MT	12,36557	54,8113	Angelim saia	Parkia pendula (Willd) Benth. Ex Walp.	Fabaceae	Hamada, M.O.S. 85	85	23/07/2023	53,60cm	15,00m	33,00m
10660	Fazenda Boa esperança- Feliz Natal, MT	12,3664	54,81176	Amescla	Trattinnickia burserifolia Mart.	Burseraceae	Hamada, M.O.S. 87	87	23/07/2023	56,60cm	14,20m	31,00m

10661	Fazenda Boa esperança- Feliz Natal, MT	12,36579	54,81199	Angelim saia	Parkia pendula (Willd) Benth. Ex Walp.	Fabaceae	Hamada, M.O.S. 88	88	23/07/2023	67,70cm	17,00m	31,00m
10662	Fazenda Boa esperança- Feliz Natal, MT	12,36691	54,81112	Angelim saia	Parkia pendula (Willd) Benth. Ex Walp.	Fabaceae	Hamada, M.O.S. 89	89	23/07/2023	83,00cm	12,90m	33,00m
10664	Fazenda Boa esperança- Feliz Natal, MT	12,36793	54,81361	Amescla	Trattinnickia burserifolia Mart.	Burseraceae	Hamada, M.O.S. 93	93	23/07/2023	61,60cm	9,00m	29,60m
10665	Fazenda Boa esperança- Feliz Natal, MT	12,36678	54,81087	Amescla	Trattinnickia burserifolia Mart.	Burseraceae	Hamada, M.O.S. 96	96	23/07/2023	42,00cm	13,80m	25,80m
10668	Fazenda Boa esperança- Feliz Natal, MT	12,37339	54,81442	Sucupira	Bowdichia nitida Spruce ex Benth	Fabaceae	Hamada, M.O.S. 105	105	24/07/2023	37,70cm	8,00m	30,40m
10669	Fazenda Boa esperança- Feliz Natal, MT	12,36947	54,81047	Sucupira	Bowdichia nitida Spruce ex Benth	Fabaceae	Hamada, M.O.S. 108	108	24/07/2023	43,50cm	10,00m	25,40m
10670	Fazenda Boa esperança- Feliz Natal, MT	12,36177	54,86732	Sucupira	Bowdichia nitida Spruce ex Benth	Fabaceae	Hamada, M.O.S. 109	109	24/07/2023	42,30cm	20,00m	35,00m
10671	Fazenda Boa esperança- Feliz Natal, MT	12,36065	54,8601	Sucupira	Bowdichia nitida Spruce ex Benth	Fabaceae	Hamada, M.O.S. 111	111	24/07/2023	42,00cm	12,00m	29,00m
10672	Fazenda Boa esperança- Feliz Natal, MT	12,36142	54,86044	Sucupira	Bowdichia nitida Spruce ex Benth	Fabaceae	Hamada, M.O.S. 113	113	24/07/2023	39,70cm	12,00m	27,00m
10673	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT	9,8292	58,29325	Muriacatia ria	Astronium lecointei Ducke	anacardiaceae	Hamada, M.O.S. 117	117	27/07/2023	63,60cm	26,00m	39,00m
10676	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,8259	58,30132	Muriacatia ria	Astronium lecointei Ducke	anacardiaceae	Hamada, M.O.S. 120	120	27/07/2023	49,40cm	26,70m	36,00m
10677	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,8238	58,30117	Muriacatia ria	Astronium lecointei Ducke	anacardiaceae	Hamada, M.O.S. 122	122	27/07/2023	65,20cm	32,00m	51,20m
10674	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,82895	58,29379	Caixeta	Simarouba amara Aubl.	simaroubaceae	Hamada, M.O.S. 118	118	27/07/2023	48,50cm	10,00m	30,00m
10678	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,82924	58,29611	Caixeta/ marupá	Simarouba amara Aubl.	simaroubaceae	Hamada, M.O.S. 123	123	27/07/2023	51,00cm	23,70m	33,70m
10680	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,82936	58,30251	Muriacatia ria	Astronium lecointei Ducke	anacardiaceae	Hamada, M.O.S. 127	127	28/07/2023	67,70cm	30,00m	43,00m
10681	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,82928	58,30232	Garrote/ Tatajuba	Bagassa guianensis Aubl	Moraceae	Hamada, M.O.S. 128	128	28/07/2023	50,70CM	19,80M	30,00M
10682	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,82772	58,304	Garrote/ Tatajuba	Bagassa guianensis Aubl	Moraceae	Hamada, M.O.S. 130	130	28/07/2023	105,00cm	21,50m	42,00M
10685	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,82758	58,30296	Garrote/ Tatajuba	Bagassa guianensis Aubl	Moraceae	Hamada, M.O.S. 133	133	28/07/2023	120,00CM	27,50m	44,00m
10686	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,82767	58,30302	Garrote/ Tatajuba	Bagassa guianensis Aubl	Moraceae	Hamada, M.O.S. 134	134	28/07/2023	100,90cm	20,50m	44,60m
10687	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,82762	58,30322	Garrote/ Tatajuba	Bagassa guianensis Aubl	Moraceae	Hamada, M.O.S. 135	135	27/07/2023	76,60cm	22,550m	39,00m
10688	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,82739	58,30328	Caixeta/ marupá	Simarouba amara Aubl.	simaroubaceae	Hamada, M.O.S. 136	136	28/07/2023	43,40cm	15,80m	34,30m
10689	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,82722	58,30313	Muriacatia ria	Astronium lecointei Ducke	anacardiaceae	Hamada, M.O.S. 137	137	28/07/2023	45,80cm	20,60m	35,20m
10690	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,81576	58,30773	Caixeta/ marupá	Simarouba amara Aubl.	simaroubaceae	Hamada, M.O.S. 140	140	29/07/2023	83,80cm	19,50m	36,00m
10691	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,818	58,30682	Caixeta/ marupá	Simarouba amara Aubl.	simaroubaceae	Hamada, M.O.S. 142	142	29/07/2023	59,10cm	13,00m	40,10m
10692	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,82955	58,29076	Amescla aroira	Protium acrense Daly	Burseraceae	Hamada, M.O.S. 151	151	29/07/2023	57,50cm	8,00m	28,00m
10693	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,82956	58,29062	Amescla aroeira	Protium acrense Daly	Burseraceae	Hamada, M.O.S. 152	152	29/07/2023	40,40cm	9,40m	23,00m

10694	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,82891	58,2871	Cedro rosa	Cedrela odorata L	Meliaceae	Hamada, M.O.S. 153	153	29/07/2023	47,90cm	8,70m	19,30m
10695	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,82898	58,28698	Cedro rosa	Cedrela odorata L	Meliaceae	Hamada, M.O.S. 154	154	30/07/2023	36,70cm	16,50m	21,60m
10696	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,8289	58,28696	Cedro rosa	Cedrela odorata L	Meliaceae	Hamada, M.O.S. 155	155	30/07/2023	54,80cm	10,20m	19,30m
10697	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,82808	58,28712	Cedro rosa	Cedrela odorata L	Meliaceae	Hamada, M.O.S. 156	156	30/07/2023	40,50cm	11,70m	21,70m
10698	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,82731	58,29071	Amescla aroeira	Protium acrense Daly	Burseraceae	Hamada, M.O.S. 157	157	30/07/2023	47,90cm	8,40m	21,20m
10699	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,82733	58,29073	Amescla aroeira	Protium acrense Daly	Burseraceae	Hamada, M.O.S. 158	158	30/07/2023	42,90cm	12,30m	21,10m
10700	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,82739	58,29147	Cedro rosa	Cedrela odorata L	Meliaceae	Hamada, M.O.S. 159	159	30/07/2023	39,00cm	20,30m	32,90m
10701	Fazenda São Nicolau/ONF Brasil-Cotriguaçu, MT.	9,82796	58,2914	Amescla aroeira	Protium acrense Daly	Burseraceae	Hamada, M.O.S. 160	160	30/07/2023	37,00cm	10,60m	22,10m