

Reconhecimento de Espécies Florestais Madeireiras Utilizando Redes Neurais Convolucionais

R. S. Noleto ^{a*}, F. C. L. Ferreira ^a, Z. G. Luis ^a, J. A. S. de Sá ^a

^a Universidade Federal do Sul e Sudeste do Pará, Marabá (PA) Brasil

*Endereço de e-mail para correspondência: raab.noleto20@gmail.com. Tel.: +55-91-986066088.

Recebido em 23/08/2024; Revisado em 22/04/2025; Aceito em 17/06/2025

Resumo

O reconhecimento de uma árvore depende da presença das características morfológicas do vegetal, como folhas, flores, raízes, caules e troncos. No entanto, a transformação da árvore em madeira beneficiada elimina essas características do vegetal. Nesse sentido, a análise da anatomia da madeira é uma alternativa para reconhecê-la quando as demais características estiverem ausentes. O objetivo deste trabalho foi demonstrar o desempenho de uma rede neural convolucional para reconhecer, por meio da anatomia da madeira, sete espécimes identificadas até o nível de espécie (*Bertholletia excelsa* Bonpl., *Cariniana estrellensis* (Raddi) Kuntze, *Erisma uncinatum* Warm., *Manilkara huberi* (Ducke) A. Chev., *Mezilaurus itauba* (Meisn.) Taub. ex Mez, *Grevillea robusta* A. Cunn. ex R. Br. e *Melia azedarach* L.) e três ID reconhecidas até o nível de gênero (*Hymenaea* sp. Mart., *Dipteryx* sp. Aubl., *Machaerium* sp. Pers.) As imagens utilizadas foram coletadas do banco de dados “Forest Species Database - Macroscopic”, disponibilizado pelo Laboratório Visão Robótica e Imagem da Universidade Federal do Paraná (UFPR). Foram utilizadas 550 imagens da anatomia das madeiras em formato JPG, com resolução de 3264 x 2448 pixels. Por meio dos testes realizados na rede neural convolucional criada, obteve-se a matriz de confusão, a precisão, o Recall e o F1-score. Foi possível demonstrar a viabilidade no reconhecimento de espécies florestais madeireiras utilizando a inteligência artificial (IA) por meio da rede neural convolucional, com acurácia de 90% nos testes submetidos, demonstrando ser uma tecnologia promissora no reconhecimento de espécies florestais madeireiras.

Palavras-Chave: Similaridade, Inteligência Artificial, Madeira.

Abstract

The recognition of a tree relies on the presence of its morphological characteristics, such as leaves, flowers, roots, stems, and trunks. However, the processing of a tree into lumber removes these distinguishing features. In this context, wood anatomy analysis becomes a viable alternative for recognition when other morphological traits are no longer available. This study aimed to demonstrate the performance of a convolutional neural network (CNN) in recognizing seven wood specimens at the species level (*Bertholletia excelsa* Bonpl., *Cariniana estrellensis* (Raddi) Kuntze, *Erisma uncinatum* Warm., *Manilkara huberi* (Ducke) A. Chev., *Mezilaurus itauba* (Meisn.) Taub. ex Mez, *Grevillea robusta* A. Cunn. ex R. Br., and *Melia azedarach* L.) and three specimens at the genus level (*Hymenaea* sp. Mart., *Dipteryx* sp. Aubl., and *Machaerium* sp. Pers.) using wood anatomical features. The images used were obtained from the “Forest Species Database – Macroscopic”, provided by the Robotics Vision and Imaging Laboratory at the Federal University of Paraná (UFPR). A total of 550 JPG-format images of wood anatomy were used, each with a resolution of 3264 × 2448 pixels. From the tests conducted on the developed CNN, the confusion matrix, precision, recall, and F1-score were obtained. The results demonstrated the feasibility of using artificial intelligence (AI), specifically convolutional neural networks, for the recognition of timber-yielding forest species, achieving an accuracy of 90% in the performed tests. These findings support the use of this technology as a promising tool for automated forest species recognition.

Keywords: Similarity, Artificial Intelligence, Wood.

1. INTRODUÇÃO

Segundo a Lei nº 9.605, de 12 de fevereiro de 1998, a penalidade para quem transporta madeira ilegal é de detenção de seis meses a um ano e multa [1]. Na maioria dos casos, para a detecção de enganos e fraudes, é necessário realizar o reconhecimento da madeira apreendida [2].

No entanto, a transformação da árvore em madeira serrada acarreta a ausência das estruturas reprodutivas e características morfológicas da árvore (flores, folhas e raízes), o que dificulta o reconhecimento das espécies florestais madeireiras, sendo essencial possuir conhecimento sobre as características anatômicas das espécies alvo de identificação [3].

O reconhecimento das espécies florestais é feito após a limpeza da superfície da madeira com um estilete e o polimento da área que será analisada, sendo possível a observação das características anatômicas macroscópicas (vasos, raios e parênquimas) [4]. Isso implica na necessidade de que o perito tenha conhecimento prévio sobre a anatomia da madeira e, além disso, exige mais tempo para a investigação.

Nesse sentido, o uso das características anatômicas aliadas à tecnologia pode ser uma alternativa de identificação de madeiras, propiciando a detecção de enganos e fraudes com mais agilidade e precisão.

Desenvolver uma rede neural robusta que reconheça diferentes espécies de madeiras permitirá criar ferramentas digitais que auxiliem peritos em campo. Essa tecnologia acrescentará um elemento importante na criação de laudos periciais, sem substituir o trabalho humano na coleta de provas e na elucidação de infrações ambientais.

O objetivo é demonstrar que a inteligência artificial pode reconhecer a madeira de espécies florestais por meio de redes neurais convolucionais. Este estudo, mesmo sem detalhar uma metodologia de coleta de imagens em campo, facilitará futuras pesquisas nessa área.

2. REDES NEURAIS ARTIFICIAIS

A inteligência artificial surge como uma alternativa para o reconhecimento de espécies florestais que possuem apenas a madeira como elemento de identificação. Como exemplo disso, as redes neurais artificiais têm demonstrado, cada vez mais, a sua utilidade para diversos fins.

As redes neurais surgiram por volta dos anos 1950, quase ao mesmo tempo em que foram criados os primeiros computadores. A ideia era simular as atividades neurais humanas, definindo componentes lógicos semelhantes aos neurônios naturais. O neurobiologista McCulloch e o estatístico Pitts foram os primeiros a propor o conceito de um neurônio como uma unidade de processamento que recebe múltiplos estímulos como entrada e gera um sinal baseado no resultado do somatório desses estímulos [5].

As redes neurais artificiais são modelos que buscam simular o processamento de informações do cérebro humano. Elas são compostas por unidades de processamento simples, os neurônios, que se unem por meio de conexões sinápticas. Uma rede neural artificial pode ser vista como um grafo, onde os nós são os neurônios e as ligações desempenham a função das sinapses [6].

As semelhanças fundamentais entre a rede neural e o cérebro humano estão no fato de que a rede adquire conhecimento do ambiente em que está inserida por meio do processo de aprendizagem, assim como acontece com o cérebro humano [7].

Nesse contexto, quando nos referimos ao reconhecimento de imagens, uma rede neural convolucional é capaz de fazê-lo. A rede neural convolucional permite que a informação passe por uma série de filtros, nas camadas de convolução, que realçam os padrões locais regulares e reduzem a dimensão dos dados originais (Figura 1) [5].




Figura 1. Redução da dimensão dos dados originais na rede neural convolucional.

Fonte: Ceccon, 2020.

Os resultados dos vários filtros são resumidos por meio de operações de pooling. As camadas de pooling são utilizadas para simplificar as informações na saída da camada convolucional [5].

Nas camadas de convolução mais profundas, espera-se que os dados, em um espaço dimensional reduzido, contenham informações suficientes sobre esses padrões locais, permitindo atribuir um valor semântico ao dado original. Em seguida, esses dados são encaminhados para a estrutura clássica de uma rede neural feedforward, destinada à tarefa de classificação [5].

3. METODOLOGIA PARA O RECONHECIMENTO DE ESPÉCIES FLORESTAIS MADEIREIRAS

Inicialmente, foram coletadas imagens macroscópicas de sete espécies florestais (*Bertholletia excelsa* Bonpl., *Cariniana estrellensis* (Raddi) Kuntze, *Erisma uncinatum* Warm., *Manilkara huberi* (Ducke) A. Chev., *Mezilaurus itauba* (Meisn.) Taub. ex Mez, *Grevillea robusta* A. Cunn. ex R. Br. e *Melia azedarach* L.) e de três gêneros (*Hymenaea* sp. Mart., *Dipteryx* sp. Aubl., *Machaerium* sp. Pers.).

As imagens foram coletadas do banco de dados “Forest Species Database - Macroscopic”, disponibilizado online gratuitamente pelo Laboratório Visão Robótica e Imagem da Universidade Federal do Paraná (UFPR).

Em seguida, criou-se a rede neural convolucional formada por diferentes camadas. A primeira camada convolucional (Conv2D) utiliza 32 filtros (ou kernels) com dimensões de 3x3 pixels. A segunda camada convolucional (Conv2D) utiliza 32 filtros com dimensões de 2x2 pixels. Para introduzir não linearidade, utilizou-se a ativação ReLU (Activation('relu')), aplicada após cada operação de convolução nas duas camadas.

Após cada par de camadas convolucionais, aplicou-se uma camada de max pooling (Max Pooling 2D). Essa camada de pooling reduz as dimensões da representação da imagem, ajudando a diminuir a quantidade de parâmetros e a computação nas camadas seguintes.

Após a camada de pooling, foi adicionada uma camada de Dropout 0.5. O dropout é uma técnica de regularização que desativa aleatoriamente uma fração (neste caso, 50%) das unidades durante o treinamento, o que ajuda a prevenir o overfitting e melhorar a generalização do modelo.

A seguir, utilizou-se a camada Flatten para transformar o tensor tridimensional resultante em um vetor unidimensional. Isso é necessário antes de alimentar os dados às camadas totalmente conectadas.

Duas camadas densas (Dense) foram adicionadas para realizar a classificação final (Fully Connected). A primeira camada densa possui 32 neurônios com uma função de ativação tangente hiperbólica (tanh), seguida por uma camada de dropout de 50%.

A última camada densa contém um número de neurônios equivalente ao número de classes (10 espécies), com uma função de ativação softmax, indicando uma tarefa de classificação multiclasse. Essa camada produzirá probabilidades para cada classe. Nessa camada também foi aplicada uma regularização L2 de 0.05 para evitar o overfitting.

Por fim, realizou-se a compilação do modelo. O modelo foi compilado utilizando a função de perda categorical_crossentropy, adequada para problemas de classificação com várias classes.

O otimizador utilizado foi o Adam e a métrica avaliada foi a acurácia. Nessa arquitetura, as camadas convolucionais são responsáveis por extrair características importantes das imagens, enquanto as camadas densas realizam a classificação com base nessas características. O uso de dropout e max pooling contribui para a regularização e redução do overfitting.

Vale ressaltar outras configurações da CNN elaborada, como o uso de data augmentation (rotação e espelhamento) para aumentar a variedade dos dados de treinamento.

A rede neural convolucional (RNC) foi balanceada com 80% dos dados destinados ao treinamento e 20% ao teste. O tamanho do lote (batch size) foi de 50 imagens por lote; o número de classes foi determinado pelo número de espécies (10); o número de épocas correspondeu a 20 iterações completas sobre o conjunto de treinamento; o número de filtros na primeira camada convolucional foi de 32; e o tamanho do pooling foi 2x2, usado para reduzir a dimensionalidade após as camadas convolucionais.

As características apresentadas à rede foram os vasos, os raios e os parênquimas.

3.1 Parênquimas

A identificação do tipo de parênquima axial é essencial para a identificação de madeiras, sendo considerada a “digital” da madeira. Por meio da identificação do tipo de parênquima, é possível determinar a que família botânica a espécie pertence. O parênquima axial é um tecido de reserva, e sua classificação é realizada conforme o desenho formado [8].

O tecido parenquimático deve ser observado em corte transversal, com a possibilidade de ocorrência de dois ou mais tipos de parênquimas ao mesmo tempo [8]. O parênquima (Fig. 2) é um dos principais tecidos encontrados na madeira e apresenta-se organizado em diferentes padrões

3.2 Raios

Os raios são feixes alongados de células parenquimáticas que atuam no armazenamento e translocação de água e solutos a curta distância, principalmente no sentido lateral. Os raios podem ser observados em seções transversais e tangenciais, a olho nu ou com auxílio de lupa. Eles podem apresentar variação considerável quanto à constituição, número e organização (arranjos) [3].

Dentre as principais características semelhantes entre as espécies, encontram-se o tipo de parênquima e algumas características dos vasos condutores, como obstruções e disposição. A seguir (Figura 2), demonstra-se algumas características anatômicas das espécies florestais estudadas.



Figura 2: Características anatômicas das espécies florestais.

A e B: *Erisma uncinatum*; C e D: *Mezilaurus itauba*; E e F: *Dipteryx* sp.; G e H: *Bertholletia excelsa*; I e J: *Hymenaea* sp.; K e L: *Manilkara huberi*; M e N: *Grevillea robusta*; O e P: *Machaerium* sp.; Q e R: *Melia Azedarach*; S e T: *Cariniana estrelensis*.

3.3 Vasos Condutores

Os arranjos dos vasos condutores da madeira são distribuições com desenhos característicos, divididos em tangencial, diagonal, radial e/ou dendrítico, podendo ser agrupados de quatro formas: solitários, múltiplos, cadeias radiais e em cachos [3].

4. RESULTADOS E DISCUSSÃO

Após a criação da rede neural convolucional e a realização dos testes, obteve-se a matriz de confusão (Tabela. 1). A partir da matriz de confusão gerada, foram

obtidas as métricas de avaliação do modelo da CNN, como a precisão, o Recall e o f1-score por espécie (Tabela 2).

Tabela 1: Matriz de Confusão

		Confusion Matrix									
Atual	Bertholletia excelsa	4006	0	5	11	1	173	0	26	0	0
	Cariniana estrellensis	61	4039	0	0	1	0	21	17	85	0
	Dipteryx sp.	386	9	5383	13	287	25	53	38	3	27
	Erisma uncinatum	32	0	0	3200	29	429	34	0	0	0
	Grevillea robusta	138	30	3	10	3593	13	247	0	190	0
	Hymenaea sp.	754	0	249	0	0	3209	12	0	0	0
	Machaerium sp.	91	0	20	33	16	47	3945	25	7	0
	Manilkara huberi	105	2	53	1	0	0	51	4012	0	0
	Melia azedarach	7	25	0	0	78	0	12	0	4102	0
	Mezilaureus itauba	0	0	9	0	0	0	3	0	0	4212
		Predicted									
		Bertholletia excelsa	Cariniana estrellensis	Dipteryx sp.	Erisma uncinatum	Grevillea robusta	Hymenaea sp.	Machaerium sp.	Manilkara huberi	Melia azedarach	Mezilaureus itauba

Fonte: Autores,2024.

Foi possível observar o valor de precisão e o valor de f1-score para cada espécie analisada (Tabela 2). A precisão é uma métrica que avalia a quantidade de verdadeiros positivos sobre a soma de todos os valores positivos [9] e o f1-score é uma média harmônica calculada com base na precisão e no recall [9].

Tabela 2: Métricas gerais de avaliação

Classification Report:				
	precision	recall	f1-score	support
Bertholletia excelsa	0.72	0.95	0.82	4224
Cariniana estrellensis	0.98	0.96	0.97	4224
Dipteryx sp	0.91	0.80	0.85	4224
Erisma uncinatum	0.98	0.88	0.93	4224
Grevillea robusta	0.90	0.85	0.87	4224
Hymenaea sp	0.82	0.76	0.79	4224
Machaerium sp	0.90	0.94	0.92	4224
Manilkara huberi	0.97	0.95	0.96	4224
Melia azedarach	0.94	0.97	0.95	4224
Mezilaureus itauba	0.99	1.00	1.00	4224
accuracy			0.91	42240
macro avg	0.91	0.91	0.91	42240
weighted avg	0.91	0.91	0.91	42240

Fonte: Autores,2024.

A espécie *B. excelsa* Bonpl. apresentou o menor valor de precisão (0,72), enquanto a espécie *Mezilaureus itauba* obteve o maior valor (0,99). A Figura 3 apresenta a precisão dos testes para cada espécie analisada.

Hymenaea sp. e *B. excelsa* Bonpl. apresentaram os menores valores de f1-score (79 e 82), enquanto a espécie *Mezilaureus itauba* (Meisn.) Taub. ex Mez. apresentou o maior valor de f1-score.

Hymenaea sp. Mart. e *Dipteryx* sp. apresentaram os menores valores de Recall (0,76 e 0,80), o maior valor de Recall foi encontrado na espécie *Mezilaureus itauba* (Meisn.) Taub. ex Mez. O recall avalia a capacidade do método de detectar com sucesso resultados classificados como positivos [9]. A figura 4 apresenta o Recall por espécie.




Figura 3: Precisão para cada espécie analisada

Fonte: Autores,2024




Figura 4: Recall por espécie

Fonte: Autores,2024

Os valores obtidos para as métricas analisadas foram considerados satisfatórios para todas as espécies observadas. Isso pode ser explicado pelo treinamento da rede, que utilizou imagens das três seções da madeira, tornando o estudo mais preciso.

4.1 Análise individual do desempenho da RNC

A partir da matriz de confusão gerada, observou-se o comportamento da rede neural convolucional no reconhecimento de cada indivíduo, uma maneira de identificar como a rede se comporta quando se apresenta diferentes imagens da anatomia de diferentes madeiras.

4.1.1 Análise da espécie *Bertholletia excelsa* Bonpl.

A espécie *B. excelsa* foi confundida 173 vezes com o gênero *Hymenaea* sp... Os falsos positivos gerados nos permitem observar as características em comum entre os espécimes que podem ter influenciado a rede.

A semelhança do parênquima de ambas as espécies pode ter influenciado o comportamento da rede neural criada, haja vista que a espécie *B. excelsa* Bonpl. pode apresentar parênquima do tipo em faixas ou linhas [10], enquanto *Hymenaea* sp. apresenta parênquima em faixa, porém associada ao vasicêntrico ou ao aliforme [11]. Os vasos de ambas as espécies possuem porosidade difusa, sendo solitários ou múltiplos, com obstruções.

Uma solução seria alimentar a rede neural criada com informações prévias sobre as principais características anatômicas das madeiras analisadas.

4.1.2 Análise da espécie *Cariniana estrellensis* (Raddi) Kuntze

A espécie *Cariniana estrellensis* (Raddi) Kuntze apresentou 85 falsos positivos com a espécie *Melia azedarach*. A espécie *Cariniana estrellensis* possui vasos em cadeias radiais [12], enquanto *Melia azedarach* L. possui vasos em múltiplos radiais [13], nos quais os vasos estão dispostos, preferencialmente, de forma paralela aos raios e perpendiculares aos anéis de crescimento.

4.1.3 Análise da espécie *Erisma uncinatum* Warm.

A espécie *Erisma uncinatum* Warm. apresentou 429 falsos positivos com *Hymenaea* sp.; a espécie *Erisma uncinatum* possui parênquima do tipo em faixa (Amorim e Arruda, 2017), enquanto o gênero *Hymenaea* sp. possui parênquima axial em faixas marginais associadas ao paratraqueal vasicêntrico ou aliforme [14], ambas apresentam parênquima em faixas.

4.1.4 Análise da espécie *Grevillea robusta* A. Cunn. ex R. Br.

A espécie *Grevillea robusta* A. Cunn. ex R. Br. apresentou 247 falsos positivos com *Machaerium* sp. O gênero *Machaerium* sp. é um dos maiores gêneros arbóreos tropicais de leguminosas, com cerca de 130 espécies distribuídas do México à Argentina [15]. Não foi possível afirmar quais características anatômicas predominantes influenciaram a rede na obtenção de falsos positivos entre as espécies.

Com base nisso, indica-se treinar a rede com espécies reconhecidas no mesmo nível de identificação. Por exemplo, comparar espécies com espécies, a fim de determinar quais características anatômicas a rede neural conseguiria distinguir entre elas ou, até mesmo, confundir e gerar falsos positivos. A partir da compreensão desses aspectos, seria possível realizar estudos com resultados mais precisos.

4.1.5 Análise da espécie *Manilkara huberi* A. Chev.

A espécie *Manilkara huberi* A. Chev. apresentou 105 falsos positivos com a espécie *B. excelsa* Bonpl.; a espécie *Manilkara huberi* possui parênquima axial do tipo em faixas estreitas ou em linhas. Os vasos possuem distribuição difusa, e parte deles é obstruída por tilos. Os raios são pouco contrastados [16].

A madeira da espécie *B. excelsa* Bonpl. apresenta porosidade difusa, com arranjo tanto solitário quanto múltiplo. Esses poros são totalmente obstruídos por tiloses [17]. O parênquima axial é do tipo em faixas estreitas, em linhas ou em faixas reticuladas [10]. O contraste dos raios é pouco distinto [17].

Tanto a espécie *Manilkara huberi* quanto *B. excelsa* Bonpl. apresentam parênquima axial em faixas estreitas ou em linhas, vasos com distribuição difusa e obstruídos, além de raios pouco contrastados.

4.1.6 Análise da espécie *Melia azedarach* L.

A espécie *Melia azedarach* L. apresentou 78 falsos positivos com a espécie *Grevillea robusta*. A espécie *Melia azedarach* L. apresenta parênquima paratraqueal vasicêntrico, confluyente e marginal [13]. Já a espécie *Grevillea robusta* apresenta parênquima axial paratraqueal vasicêntrico e confluyente em faixas tangenciais.

Ao observar as características anatômicas de ambas, percebe-se em comum o parênquima axial do tipo paratraqueal vasicêntrico e confluyente.

4.1.7 Análise da espécie *Mezilaurus itauba* (Meisn.) Taub. ex Mez

A espécie *Mezilaurus itauba* (Meisn.) Taub. ex Mez. apresentou 9 falsos positivos com a espécie *Dipteryx* sp. A espécie *Mezilaurus itauba* apresenta vasos com distribuição difusa, predominantemente em múltiplos radiais de 2 a 3 dispostas em cadeias radiais, maioria dos vasos são obstruídos por tilos [16].

Já o gênero *Dipteryx* sp. possui vasos predominantemente solitários e ocasionalmente múltiplos de 2 e 3, pequenos, poucos, de porosidade difusa, arranjo tangencial, presença de obstrução por tiloses [18]. Ambas possuem vasos com porosidade difusa, múltiplos e obstruídos por tiloses.

4.1.8 Análise do gênero *Hymenaea* sp. Mart.

Hymenaea sp. Mart. foi confundido com *B. excelsa* Bonpl. 754 vezes. Os falsos positivos gerados nos permitem observar as características em comum entre as espécies que podem ter influenciado a rede, ambas espécies podem apresentar parênquima do tipo em faixas ou linhas [10] e os vasos de ambas as espécies possuem porosidade difusa, sendo solitários ou múltiplos com obstruções.

4.1.9 Análise do gênero *Dipteryx* sp. Aubl

O gênero *Dipteryx* sp. Aubl apresentou 386 falsos positivos com *B. excelsa* Bonpl. O gênero *Dipteryx* sp. Aubl. possui vasos visíveis a olho nu, predominantemente solitários e ocasionalmente múltiplos, com porosidade difusa com obstrução por tiloses [18].

Enquanto na espécie *B. excelsa* Bonpl. é possível verificar a presença dos poros a olho nu, que apresentam porosidade difusa e arranjo tanto solitário quanto múltiplo. Esses poros são totalmente obstruídos por tiloses [17], ou seja, ambas apresentam vasos solitários e múltiplos, porosidade difusa com presença de obstrução por tiloses e raios finos ou pouco distintos.

4.1.10 Análise da espécie *Machaerium* sp. Pers.

Já o gênero *Machaerium* sp. Pers. apresentou 91 falsos positivos com *B. excelsa* e identificar as características semelhantes entre *Machaerium* sp. Pers. e *B. excelsa* Bonpl. que podem ter influenciado a rede torna-se difícil, uma vez que, *Machaerium* sp. foi reconhecido a nível de gênero e possui cerca de 130 espécies.

Com base na observação da matriz de confusão gerada, depreende-se que os erros de reconhecimento das espécies poderiam ser minimizados ao informar à RNC as diferenças anatômicas entre as espécies, principalmente, o tipo de parênquima (Figura 5).




Figura 5. Tipos de Parênquimas encontrados nas espécies com maiores ocorrências de falso positivo.

O parênquima destaca-se como uma das características mais semelhantes entre as espécies com maior número de falsos positivos entre si. Essa semelhança reforça a necessidade de estudos que aprofundem a análise desse elemento, contribuindo para o desenvolvimento de redes neurais capazes de utilizá-lo como um dos principais parâmetros no reconhecimento de espécies florestais madeireiras.

4. CONCLUSÕES

O presente estudo demonstrou, por meio das métricas obtidas, o potencial das redes neurais convolucionais para o reconhecimento de madeira a partir de diferentes imagens macroscópicas, alcançando um alto valor da média harmônica entre precisão e f1-score.

Uma vez que esse valor está elevado, significa que a acurácia geral de 91%, obtida neste estudo, é relevante. Sabe-se que a acurácia varia de zero a 100%, e, quanto maior o valor, maior é a confiança nos resultados. Isso demonstra que a rede criada não necessita de muitas alterações e, portanto, mostrou-se uma alternativa eficiente para o reconhecimento de espécies florestais, com possibilidade de aprimoramento e contribuição significativa no reconhecimento de espécies florestais madeireiras.

5. AGRADECIMENTOS

Os autores agradecem às agências financiadoras que apoiaram este estudo, especialmente [Universidade Federal do Sul e Sudeste do Pará (UNIFESSPA), Fundação Amazônia de Amparo a Estudos e Pesquisas (FAPESPA) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo suporte financeiro fornecido durante o desenvolvimento desta pesquisa. Reconhecemos a importância de tais investimentos para o avanço científico e tecnológico, bem como para a promoção de soluções que beneficiem a sociedade como um todo.

6. REFERÊNCIAS BIBLIOGRÁFICAS

[1] Brasil. Lei n.º 9.605, de 12 de fevereiro de 1998. Presidência da República, Brasília (2021).

[2] J.T.S. Oliveira. Propriedades físicas e mecânicas da madeira. In: J.T.S. Oliveira; N.C. Fiedler; M. Nogueira (orgs.). Tecnologias aplicadas ao setor madeireiro. Suprema Gráfica e Editora Ltda., Visconde do Rio Branco: 129–163 (2007).

[3] P.C. Botosso. Identificação macroscópica de madeiras: guia prático e noções básicas para o seu reconhecimento. Embrapa Florestas, Colombo (2011).

[4] L.K.V. dos S. Souza; L.N. Coelho. Identificação de madeiras. UFOPA, Santarém (PA): 29 p. (2024).

[5] R. Ceccon. Aplicações de redes neurais convolucionais para classificação de imagens. Rev. Comput. Int. Artif. 10(2): 123–145 (2020).

[6] E. Teodoro. Redes Neurais. Network Technologies (Nova Odessa) 1/2(1/2): 57–70 (2003).

[7] S. Haykin. Redes neurais: princípios e práticas. 2. ed. Bookman, São Paulo (2001).

[8] L.K.V. dos S. Souza; L.N. Coelho. Identificação de madeiras. UFOPA, Santarém (PA): 29 p. (2024).

[9] D. Mariano. Métricas de avaliação em machine learning: acurácia, sensibilidade, precisão, especificidade e F-score. Rev. Bras. Bioinform. Biol. Comput. (2021).

[10] Serviço Florestal Brasileiro (SFB). Características e identificação de madeira. Brasília: SFB (2022).

[11] Instituto de Pesquisas Tecnológicas (IPT). Caracterização anatômica das madeiras do gênero Hymenea. São Paulo: IPT (2023).

[12] R.F. Cury; M.E. Filho. Características anatômicas da madeira de Cariniana estrellensis. Rev. Bras. Bot. 34(3): 345–356 (2011).

[13] D.A. Siegloch; Outros autores. Características anatômicas da madeira de Melia azedarach. Rev. Bras. Bot. 38(4): 445–459 (2015).

[14] A.S. Amorim; S.M. Arruda. Características anatômicas da madeira de Erisma uncinatum. Rev. Ciênc. Florest. 28(2): 123–135 (2017).

[15] Empresa Brasileira de Pesquisa Agropecuária (Embrapa). Informação Tecnológica, Brasília (2021).

[16] J.R. Neta. Anatomia e identificação de madeiras da Amazônia. 1. ed. Editora Amazônica, Manaus (2023).

[17] R.C. Alves. Elaboração de um atlas e de uma chave para identificação das principais madeiras comercializadas no estado do Espírito Santo. TCC – Universidade Federal do Espírito Santo, Centro de Ciências Agrárias, Departamento de Engenharia Florestal, Espírito Santo (2010).

[18] R.A. Jacomé. Características anatômicas da madeira do gênero Dipteryx. Rev. Bras. Bot. 45(2): 200–215 (2021).