

Reconhecimento de espécies florestais Amazônicas utilizando imagens de superfícies transversais

Artur Jefferson F. da Silva¹, Jandrei Sartori Spancerski¹, Kelyn Schenatto¹, Silvana Nisgoski², Pedro Luiz de Paula Filho¹
Universidade Tecnológica Federal do Paraná - UTFPR, Medianeira, Brasil¹,
Universidade Federal do Paraná - UFPR - Curitiba, Brasil²,

Email: arthurus@gmail.com, jandreisst@gmail.com, kelynschenatto@gmail.com, silvana.ufpr@gmail.com, pedrol@utfpr.edu.br

Abstract—Environmental monitoring research has spurred the development of various technologies for ecosystem conservation. This paper explores the application of the YOLOv8 architecture for identifying Amazonian tree species using computer vision techniques. The study focuses on analyzing transverse wood section images, with a publicly available dataset comprising 2,160 images across 18 distinct species. The model was trained and validated, achieving high accuracy in species recognition, with test results showing accuracy levels up to 99%. The goal is to develop a solution that accurately recognizes species, aiding forest protection and improving environmental enforcement against illegal logging.

Keywords—environmental monitoring, YOLOv8; species identification; computer vision; Amazon biome; illegal logging.

Resumo—A pesquisa em monitoramento ambiental impulsionou o desenvolvimento de diversas tecnologias aplicadas à conservação dos ecossistemas. Este trabalho explora a aplicação da arquitetura YOLOv8 para a identificação de espécies arbóreas amazônicas utilizando técnicas de visão computacional. O estudo foca na análise de imagens de cortes transversais da madeira, com um banco de dados público compreendendo 2.160 imagens de 18 espécies distintas. O modelo foi treinado e validado, alcançando alta precisão no reconhecimento das espécies, com resultados de teste demonstrando taxas de acerto de até 99%. O objetivo é desenvolver uma solução que permita reconhecer espécies com precisão, contribuindo para a proteção da floresta e melhorando a fiscalização contra o desmatamento ilegal.

Palavras-chave—monitoramento ambiental; YOLOv8; identificação de espécies; visão computacional; bioma amazônico; exploração ilegal.

I. INTRODUÇÃO

A demanda por pesquisas na área de monitoramento ambiental tem refletido no aumento do desenvolvimento de diversas tecnologias aplicadas à conservação dos ecossistemas. Nesse sentido, houve também um aumento significativo nos estudos focados em temas como a identificação de espécies florestais, o monitoramento do desmatamento e de outras atividades consideradas ilegais. Essas pesquisas são especialmente relevantes no contexto da Floresta Amazônica, cuja capacidade dessas espécies de enfrentar as mudanças ambientais globais é motivo de crescente preocupação [1].

A floresta amazônica exerce um papel determinante na regulação do clima global, tanto pela sua capacidade de absorção de dióxido de carbono (CO_2) quanto pela vasta quantidade de recursos hídricos que ela oferece [1], [2]. Entretanto, essa região enfrenta graves ameaças, incluindo incêndios que se intensificam nos períodos de seca e o desmatamento, este é frequentemente resultado da intervenção humana direta, com as mudanças climáticas agravando seus efeitos. A extração ilegal de madeira, em particular, é um dos principais motores do desmatamento, causando danos irreparáveis ao bioma [3]. A exploração madeireira ilegal na Amazônia é alimentada pelo elevado valor comercial de muitas de suas espécies arbóreas. Deste modo, a identificação precisa dessas espécies é indispensável para uma gestão florestal sustentável. No entanto, os métodos atuais de identificação e classificação ainda são amplamente manuais, o que limita a efetividade das estratégias de conservação. [4], [5].

Para enfrentar esses problemas, pesquisas recentes têm explorado o potencial das técnicas de aprendizado de máquina para o reconhecimento de espécies arbóreas [4], [6]. Dentre as metodologias investigadas, destacam-se as Máquinas de Vetores de Suporte (SVM), Redes Neurais Artificiais (RNAs) e o método *K-Nearest Neighbors* (K-NN). Apesar do progresso, a identificação automatizada de espécies ainda enfrenta obstáculos importantes, especialmente devido à semelhança entre as características de várias espécies, como textura, cor, estrutura e cheiro [6].

Recentemente, a arquitetura *You Only Look Once* (YOLO) trouxe uma revolução no campo da visão computacional, especialmente na tarefa de detecção de objetos em imagens e vídeos. Diferente dos métodos tradicionais, o YOLO trata a detecção como um problema de regressão unificado, permitindo que a rede neural analise a imagem inteira de uma só vez. Essa abordagem resulta em uma detecção extremamente eficiente, com menor tempo de processamento e maior precisão [7]. Desde seu surgimento, o YOLO passou por várias evoluções,

culminando no lançamento do YOLOv8 em 2023. Esta versão incorporou avanços significativos em precisão, capacidade de detecção em diferentes escalas, e robustez contra desafios comuns da visão computacional, como oclusões e variações de iluminação [8], [9].

Dessa forma, a escolha por essa versão se baseia em suas capacidades aprimoradas de detecção, que são importantes para o reconhecimento adequado de espécies em imagens de cortes transversais. Essa versão apresenta um design sem âncoras e cabeças separadas, o que favorece uma adaptação mais eficaz às variações nas imagens e contribui para um processamento mais ágil em tempo real [9].

Vale destacar que, enquanto o YOLOv8 é acessível para fins de pesquisa e desenvolvimento, a versão requer uma licença comercial da *Ultralytics* para ser utilizada em produtos com fins lucrativos. Esta característica pode influenciar a escolha da arquitetura em aplicações comerciais, mas não limita sua relevância para o desenvolvimento de protótipos e soluções experimentais em pesquisa [10].

No contexto da identificação de espécies arbóreas, o uso do YOLOv8 tem mostrado resultados promissores. A aplicação do YOLOv8 em imagens de cortes longitudinais e diferentes vistas das principais seções anatômicas da madeira permite uma classificação mais precisa e eficiente.

Os avanços recentes podem facilitar a detecção e classificação automáticas das espécies, reduzindo a necessidade de processos manuais e melhorando a fiscalização contra a extração ilegal de madeira [11], [12], [7], [8], [13].

Estudos sugerem que há muitas abordagens promissoras para aumentar a precisão no reconhecimento de espécies arbóreas por meio de *Deep Learning* (DL), o que pode contribuir significativamente para o combate ao desmatamento ilegal na Amazônia.

O objetivo desse trabalho é explorar e implementar a arquitetura YOLOv8 na identificação de espécies arbóreas do bioma amazônico, utilizando técnicas de visão computacional. Focando especificamente na análise de imagens de cortes transversais da madeira, o trabalho envolve a construção de um *dataset* abrangente para treinar e validar o modelo. O objetivo é desenvolver uma solução que permita reconhecer com precisão as espécies, contribuindo para a proteção da floresta e melhorando a fiscalização contra o desmatamento ilegal. A aplicação do YOLOv8, devido às suas melhorias em velocidade e precisão, oferece uma abordagem promissora para superar os desafios presentes nas metodologias tradicionais, promovendo uma gestão florestal mais sustentável.

II. METODOLOGIA

O desenvolvimento deste trabalho iniciou-se com a criação de um *Dataset* abrangente contendo imagens de diferentes

espécies do bioma amazônico. Para a coleta das imagens, foi utilizado um Microscópio Digital USB 1000x Zoom Câmera 2.0 MP Pro, que permitiu a captura de imagens transversais de alta resolução das amostras. O *Dataset* final compreende 18 espécies distintas, com 120 imagens capturadas para cada uma, totalizando 2,160 imagens. Este conjunto de dados foi essencial para o treinamento de um modelo de aprendizado profundo, capaz de classificar as espécies com base em entradas visuais simples, fornecendo uma base sólida para a análise subsequente.

Na Figura 1, são apresentadas algumas amostras do *Dataset* criado para a realização dos estudos descritos neste artigo. Esta figura ilustra a diversidade e a qualidade das imagens capturadas, destacando a riqueza de detalhes que o microscópio digital foi capaz de registrar. A variedade de espécies e a quantidade de imagens disponíveis no *Dataset* garantem um treinamento robusto do modelo, aumentando a precisão e a confiabilidade das classificações realizadas.




Fig. 1. Amostras do *Dataset* criado. Autoria Própria.

Para garantir uma melhor compreensão e facilitar a consulta das imagens utilizadas neste estudo, apresentamos a seguir uma Tabela que detalha a Figura 1, listando os nomes de todas as espécies abordadas no artigo. Essa Tabela funciona como um guia prático para localizar e identificar cada imagem, oferecendo uma visão organizada dos elementos visuais que sustentam nossa análise.

A Tabela I lista as figuras com suas respectivas descrições e informações com os nomes das espécies.

TABELA I
NOMES DAS ESPÉCIES

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

Espécies Florestais. Autoria Própria.

Uma metodologia específica foi desenvolvida para facilitar a anotação das imagens com o objetivo de classificação. O processo de criação dessa metodologia é ilustrado no fluxograma da Figura 2, que apresenta em detalhes cada etapa, desde a captura das imagens até as fases de treinamento e validação do modelo de DL.




Fig. 2. Fluxograma de atividades. Autoria Própria.

A. TREINAMENTO

Para o treinamento do modelo de reconhecimento de padrões em amostras de madeira, foi utilizado o modelo YOLOv8,

conhecido pela sua eficiência em tarefas de detecção e classificação de imagens. A escolha deste modelo se deve à sua capacidade de balancear precisão e velocidade, o que é crucial para aplicações que exigem processamento em tempo real ou em ambientes de recursos limitados.

1) *Conjunto de Dados*: O conjunto de dados utilizado para o treinamento foi armazenado no *Google Drive*, o que facilitou tanto a manipulação quanto o acesso durante o desenvolvimento. A distribuição foi feita da seguinte forma: 50% das amostras foram destinadas ao treinamento, 10% para validação e 40% para testes. Essa divisão foi escolhida para garantir que o modelo tivesse uma ampla base de aprendizado, ao mesmo tempo em que era continuamente avaliado e testado com amostras que não foram vistas anteriormente. Assim, buscou-se maximizar a capacidade de generalização do modelo.

2) *Estratégias de Aumento de Dados*: Para melhorar a robustez e a capacidade de generalização do modelo, diversas técnicas de aumento de dados (*Data Augmentation*) foram aplicadas. O YOLOv8 é composto por três componentes principais [8], [9]:

- **Backbone**: Responsável pela extração das características da imagem usando uma variante do *Cross Partial Stage* (CSP), que otimiza a complexidade computacional.
- **Neck**: Integra informações contextuais através do módulo PAN-FPN, promovendo a fusão de informações em múltiplas escalas.
- **Head**: Gera as saídas da rede, como as caixas delimitadoras, adotando uma abordagem sem âncoras para melhorar a detecção.

Essas técnicas são fundamentais em projetos que envolvem conjuntos de dados limitados ou desequilibrados, pois criam novas amostras virtuais a partir das imagens originais, introduzindo variações que o modelo deve aprender a reconhecer:

- **Mixup**: Com um fator de 0,1, o *Mixup* cria uma nova amostra combinando aleatoriamente duas imagens. Essa prática foi adotada para ajudar o modelo a lidar com variações na aparência das classes, além de suavizar as fronteiras entre elas. Isso é particularmente útil em cenários onde as classes não são completamente distintas [14].
- **Mosaic**: Configurado com um fator de 0,3, o *Mosaic* combina quatro imagens diferentes em uma única amostra. Essa técnica foi escolhida para permitir que o modelo aprenda com múltiplas variações simultaneamente, especialmente em imagens que apresentam diferentes escalas e perspectivas. A aplicação desse parâmetro foi realizada para aprimorar o desempenho do modelo em

cenários complexos [15].

3) *Configurações de Treinamento*: O treinamento foi configurado para ocorrer ao longo de 150 épocas, um número considerado suficiente para que o modelo pudesse aprender padrões complexos nos dados. Durante esse processo, o parâmetro *dropout* foi ajustado para 0,1. O *dropout* é uma técnica de regularização que remove temporariamente uma fração dos neurônios da rede, juntamente com todas as suas conexões, durante cada iteração de treinamento [16]. Essa técnica foi implementada para prevenir que o modelo se tornasse excessivamente dependente de neurônios específicos, o que poderia levar ao *overfitting*. Conseqüentemente, o *dropout* ajudou a melhorar a capacidade do modelo de generalizar para novos dados, tornando-o mais robusto contra variações inesperadas.

4) *Validação e Otimização*: Durante o processo de treinamento, a validação foi ativada (*val=True*) em cada época. Ou seja, ao final de cada época, o modelo foi reavaliado em um conjunto de validação separado. Essa prática foi implementada para monitorar o desempenho do modelo em dados que ele não viu durante o treinamento, fornecendo uma métrica objetiva para ajustes adicionais de hiperparâmetros.

Ao fim dessas etapas, o tempo total de processamento foi registrado ao final do treinamento, fornecendo *insights* sobre a eficiência computacional do modelo. A combinação de um modelo avançado como o YOLOv8, técnicas robustas de aumento de dados, e um processo de validação contínuo resultou em um modelo bem treinado, preparado para a tarefa de classificação de amostras de madeira com alta precisão.

III. EXPERIMENTOS

Após o treinamento do modelo YOLOv8 com as imagens do *dataset* previamente descrito, foram obtidos resultados que evidenciam a eficácia das técnicas aplicadas como mostrado na Figura 3. No caso de modelos de classificação de imagens que utilizam a arquitetura YOLO com o pacote *ultralytics*, as métricas típicas como *accuracy*, *precision*, *recall* e *f1_score* não são calculadas da mesma forma que em tarefas de classificação de texto ou de previsão. Para modelos de classificação de imagens, as métricas principais que são calculadas incluem *top1_acc* e *top5_acc*, que indicam a precisão do modelo em prever a classe correta (ou entre as top 5 classes).

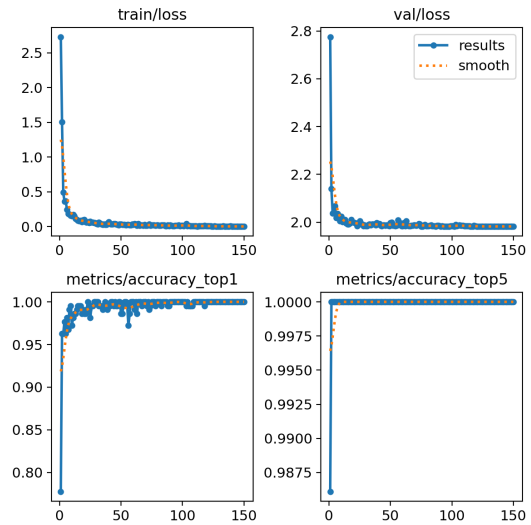


Fig. 3. Treinamento do Modelo. Autoria Própria.

Nesta seção, serão discutidos esses resultados, com destaque para as iterações de maior impacto no processo de treinamento e as estratégias que contribuíram para o aumento da generalização do modelo.

1) *Train/Val Loss*: A análise dos valores ao longo do treinamento do modelo revela uma tendência contínua de diminuição da perda, indicando um processo de aprendizado eficaz. Inicialmente, a perda começa em um valor elevado de 2,7316, refletindo um alto grau de erro. Com o progresso do treinamento, observa-se uma redução significativa, com a perda eventualmente estabilizando-se em valores baixos, como 0,00203.

Essa estabilização sugere que o modelo atingiu um ponto de convergência, onde melhorias adicionais são mínimas. As pequenas flutuações nos valores de perda são normais, indicando a robustez do modelo. A ausência de grandes variações ao longo do treinamento sugere que problemas como *overfitting* ou *underfitting* foram evitados. Esses resultados demonstram a eficácia do processo de treinamento e a capacidade do modelo de generalizar bem a partir dos dados de treinamento.

2) *Val/Val Loss*: A análise dos valores de *val/loss* ao longo do treinamento do modelo revela que, embora haja uma leve diminuição inicial, os valores rapidamente se estabilizam em torno de 1,982, sem uma tendência clara de redução contínua. Inicialmente, o valor de *val/loss* começa em 2,7754, refletindo um nível alto de erro nas previsões. No entanto, ao contrário

do esperado, o valor não diminui significativamente após as primeiras épocas, mantendo-se em um patamar elevado.

Essa estabilização em valores altos sugere que o modelo pode estar enfrentando dificuldades em generalizar para os dados de validação, possivelmente devido a problemas como *overfitting*, onde o modelo aprende os detalhes dos dados de treinamento, mas não consegue performar bem em dados novos. Além disso, a ausência de uma tendência clara de melhoria após a estabilização inicial pode indicar que o modelo atingiu um platô de performance, sem melhorias adicionais significativas.

Essa análise dos valores de *val/loss* sugere que o processo de treinamento pode não estar tão bem-sucedido quanto inicialmente pensado, sendo necessário revisar os hiperparâmetros ou os dados utilizados para melhorar a generalização do modelo.

3) *Accuracy_top1* e *Accuracy_top5*: A precisão *top1* e *top5* são métricas fundamentais para avaliar o desempenho de modelos de classificação, especialmente em tarefas complexas com um grande número de classes possíveis.

A métrica *accuracy_top1* mede a frequência com que a previsão principal do modelo (aquela com maior probabilidade) coincide com a classe correta. No seu caso, os valores de *accuracy_top1* começam em 0,77778 e rapidamente convergem para 1,0, indicando que o modelo se tornou altamente confiável em identificar a classe correta na primeira tentativa. Essa rápida convergência sugere que o modelo aprendeu rapidamente as características relevantes dos dados e foi capaz de aplicá-las de forma consistente.

Por outro lado, a métrica *accuracy_top5* mede a frequência com que a classe correta está entre as cinco principais previsões do modelo. No seu caso, os valores de *accuracy_top5* permaneceram consistentemente em 1,0 ao longo de todo o treinamento. Isso indica que, desde o início, o modelo sempre incluiu a classe correta entre suas cinco principais previsões, refletindo uma robustez significativa em capturar a classe correta mesmo quando ela não é a previsão principal.

A combinação desses resultados destaca a eficácia e a confiabilidade do modelo. A alta precisão *top1* mostra que o modelo faz escolhas corretas na primeira tentativa, essencial em aplicações que exigem decisões rápidas e precisas. A precisão *top5* consistentemente alta demonstra que o modelo também oferece previsões alternativas confiáveis, o que é valioso em cenários onde múltiplas respostas podem ser úteis. Esses resultados indicam que o modelo não só aprendeu a identificar corretamente as classes principais, mas também a fornecer opções alternativas de alta qualidade, evidenciando sua capacidade de generalização e robustez.

4) *Validando o Modelo de Teste*: Para analisar a eficácia do modelo treinado, a Tabela II mostra informações importantes sobre o desempenho do classificador na identificação de espécies arbóreas. Embora o treinamento tenha gerado uma alta taxa de acertos em 100%, é importante notar que, ao ser testado com dados novos, o modelo ainda apresenta alguns erros, especialmente quando as espécies são semelhantes.

TABELA II
CLASSIFICAÇÃO DAS ESPÉCIES

Número	Real	Prevista
01	Catingueira	Catingueira 0,99, Garapa 0,01
02	Catingueira	Catingueira 0,99, Garapa 0,01
03	Jacareúba	Jacareúba 0,99, Cupiúba 0,01
04	Castanha de Macaco	Castanha de Macaco 0,99, Maçaranduba 0,01
05	Castanha de Macaco	Castanha de Macaco 0,99, Timbaúva 0,01
06	Garapa	Garapa 0,99, Maçaranduba 0,01
07	Garapa	Garapa 0,99, Maçaranduba 0,01
08	Garapa	Garapa 0,99, Maçaranduba 0,01
09	Garapa	Garapa 0,99, Maçaranduba 0,01
10	Garapa	Garapa 0,99, Maçaranduba 0,01
11	Sucupira preta	Sucupira preta 0,99, Roxinho 0,01
12	Pariri	Pariri 0,99, Maçaranduba 0,01
13	Pariri	Pariri 0,99, Mogno 0,01
14	Pariri	Pariri 0,99, Maçaranduba 0,01

Resultado teste com espécies. Autoria Própria.

Nota-se que para várias amostras, o modelo alcançou uma precisão de 99% na identificação correta das espécies. No entanto, o modelo também indicou, em 1% dos casos, a possibilidade de confusão com outra espécie. Isso sugere que, apesar da alta precisão, ainda há uma margem mínima de incerteza, onde o modelo identifica uma espécie similar à real.

A Figura 4, mostra imagens das espécies reais que foram confundidas.




Fig. 4. Imagens confundidas. Autoria Própria.

Além dos resultados de 99% apresentados na Tabela II, também registramos taxas de acerto ligeiramente inferiores, conforme mostrado na Tabela III. Nesses casos, o modelo ainda demonstra um bom desempenho, mas apresenta uma margem de erro um pouco maior. A Tabela III indica que a precisão na identificação correta das espécies caiu para 98% em várias amostras, resultando em até 2% de chance de confusão com outras espécies.

TABELA III
CLASSIFICAÇÃO DAS ESPÉCIES

Número	Real	Prevista
01	Catingueira	Catingueira 0,98, Garapa 0,02
02	Catingueira	Catingueira 0,98, Garapa 0,02
03	Catingueira	Catingueira 0,98, Garapa 0,01, Cupiúba 0,01
04	Catingueira	Catingueira 0,98, Maçaranduba 0,02
05	Castanha-de-Macaco	Castanha-de-Macaco 0,98, Pariri 0,02
06	Garapa	Garapa 0,98, Maçaranduba 0,02
07	Garapa	Garapa 0,98, Roxinho 0,01, Cupiúba 0,01
08	Catingueira	Catingueira 0,97, Garapa 0,03
09	Jacareúba	Jacareúba 0,97, Maçaranduba 0,02, Roxinho 0,01
10	Tauari	Tauari 0,97, Cedro 0,02, Cupiúba 0,01
11	Roxinho	Roxinho 0,96, Maçaranduba 0,04
12	Cupiuba	Cupiuba 0,95, Jacareúba 0,05
13	Maçaranduba	Maçaranduba 0,95, Castanha-de-Macaco 0,04, Angelim-vermelho 0,01
14	Maçaranduba	Maçaranduba 0,81, Pariri 0,18, Roxinho 0,01
15	Castanha de Macaco	Castanha-de-Macaco 0,71, Maçaranduba 0,29
16	Pariri	Maçaranduba 0,75, Pariri 0,25
17	Roxinho	Roxinho 0,57, Maçaranduba 0,43
18	Maçaranduba	Castanha-de-Macaco 0,53, Maçaranduba 0,43, Pariri 0,04
19	Muiracatiara	Muiracatiara 0,51, Catingueira 0,49
20	Pariri	Pariri 0,43, Jacareúba 0,35, Roxinho 0,20, Tauari 0,01, Castanha de Macaco 0,01

Resultado teste com espécies. Autoria Própria.

A Figura 5 ilustra as espécies que foram confundidas.




Fig. 5. Imagens confundidas. Autoria Própria.

É importante observar que, em alguns casos específicos, a confiança do modelo na classificação correta diminuiu ainda mais, caindo para até 43%. Essas quedas de precisão indicam que, para espécies com características visuais semelhantes ou com variações mais sutis, o modelo ainda enfrenta desafios na diferenciação exata.

Isso pode ser atribuído a vários fatores, como a quantidade insuficiente de amostras disponíveis para treinamento, que pode ter limitado a capacidade do modelo de aprender nuances mais sutis entre as espécies. Além disso, a similaridade morfológica entre as espécies pode ter contribuído para essa confusão ou outras abordagens.

IV. CONCLUSÃO

O uso do modelo YOLOv8 para a identificação de espécies arbóreas amazônicas mostrou-se altamente eficaz, apresentando uma precisão significativa que pode transformar a forma como pode-se monitorar e preservar a biodiversidade da região amazônica. As técnicas de aumento de dados aplicadas no treinamento do modelo contribuíram substancialmente para seu desempenho, evidenciando o potencial de abordagens automatizadas na catalogação e no monitoramento da flora. Este trabalho não apenas reforça a importância da tecnologia no apoio à conservação ambiental, mas também abre caminho para a implementação de estratégias mais eficazes e sustentáveis de gestão florestal.

Além das análises transversais realizadas, a pesquisa pode se expandir para incluir estudos que avaliem as características organolépticas das amostras de madeira, como textura, cor e cheiro. Essas avaliações sensoriais oferecem informações valiosas sobre a qualidade e aplicabilidade das diferentes espécies em cenários práticos. Também é possível conduzir comparações entre as amostras tangenciais e radiais, o que proporcionaria uma visão mais ampla das variações na estrutura e no comportamento da madeira.

Integrar essas novas abordagens não só fortaleceria a base de dados, mas também contribuiria para o desenvolvimento de modelos mais precisos e úteis em aplicações científicas e industriais. Explorar essas direções permitirá uma caracterização mais completa das espécies de madeira, promovendo avanços tanto no entendimento científico quanto nas suas aplicações práticas, ampliando o impacto na proteção da biodiversidade amazônica.

A solução desenvolvida, embora dependa da captura manual de imagens com microscópio, pode ainda assim trazer melhorias para a fiscalização. Ao aumentar a precisão na identificação da espécie arbórea, especialmente para amostras analisadas em laboratório, a aplicação prática desse modelo pode facilitar o trabalho de técnicos ambientais e laboratoriais. O principal benefício está na capacidade de identificação confiável, permitindo um controle mais preciso das regulamentações florestais. Além disso, os resultados podem ser integrados a bancos de dados oficiais, oferecendo apoio para ações de fiscalização e acompanhamento de espécies em risco, ajudando a reduzir a extração ilegal e a rastrear a origem da madeira.

AGRADECIMENTOS

Agradecemos ao CNPq pela bolsa de Produtividade em Desen. Tec. e Extensão Inovadora (DT-II - Processo: 303279/2023-0).

REFERÊNCIAS

- [1] C. A. Boulton, T. M. Lenton, and N. Boers, "Pronounced loss of amazon rainforest resilience since the early 2000s," *Nature Climate Change*, vol. 12, pp. 271–278, Mar. 2022. [Online]. Available: <https://doi.org/10.1038/s41558-022-01287-8>
- [2] L. V. Gatti, L. S. Basso, J. B. Miller, M. Gloor, L. G. Domingues, H. L. G. Cassol, G. Tejada, L. E. O. C. Aragão, C. Nobre, W. Peters, L. Marani, E. Arai, A. H. Sanches, S. M. Corrêa, L. Anderson, C. V. Randow, C. S. C. Correia, S. P. Crispim, and R. A. L. Neves, "Amazonia as a carbon source linked to deforestation and climate change," *Nature Climate Change*, vol. 595, pp. 388–393, Mar. 2021. [Online]. Available: <https://doi.org/10.1038/s41586-021-03629-6>
- [3] R. B. Souza, R. B. B. Souza, F. R. F. Júnior, and P. P. de Almeida Neto, "Efeitos da extração de madeira sobre a biodiversidade em florestas tropicais," *Natural Resources*, vol. 11, p. 3, Jul. 2021. [Online]. Available: <https://doi.org/10.6008/CBPC2237-9290.2021.003.0005>
- [4] P. L. de Paula Filho, "Reconhecimento de espécies florestais através de imagens macroscópicas," Ph.D. dissertation, Universidade Federal do Paraná, 2012. [Online]. Available: <https://acervodigital.ufpr.br/handle/1884/29781>
- [5] H. A. Gharar, U. Khairuddin, R. Yusof, A. S. M. Khairuddin, and A. Ahmad, "New Feature Extraction for Wood Species Recognition System via Statistical Properties of Line Distribution," *2021 International Conference on Electrical, Communication, and Computer Engineering (ICECCE)*, pp. 1–5, Feb. 2021. [Online]. Available: https://ieeexplore.ieee.org/abstract/document/9514115?casa_token=RMjwFrNlalkAAAAA:6tAX9R42bMDOX-EAr2KzV6xKVogMnBL-G9g2JuCOfxSJryikIDQ9I-52CZ07b2W1bjC45_Iv8Y_Amb4
- [6] S. Neethu and L. B. Sylva, "Wood Species Recognition Using Machine Learning," *2021 Fourth International Conference on Microelectronics, Signals & Systems (ICMSS)*, pp. 1–6, Feb. 2021. [Online]. Available: <https://ieeexplore.ieee.org/document/9673601>
- [7] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You only look once: Unified, real-time object detection," 2016. [Online]. Available: <https://arxiv.org/abs/1506.02640>
- [8] F. Solimani, A. Cardellicchio, G. Dimauro, A. Petrozza, S. Summerer, F. Cellini, and V. Renò, "Optimizing tomato plant phenotyping detection: Boosting yolov8 architecture to tackle data complexity," *Computers and Electronics in Agriculture*, vol. 218, p. 108728, 2024. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0168169924001194>
- [9] J. Terven, D.-M. Córdova-Esparza, and J.-A. Romero-González, "A comprehensive review of yolo architectures in computer vision: From yolov1 to yolov8 and yolo-nas," *Machine Learning and Knowledge Extraction*, vol. 5, no. 4, p. 1680–1716, Nov. 2023. [Online]. Available: <http://dx.doi.org/10.3390/make5040083>
- [10] Ultralytics, "Enterprise software license," 2023. [Online]. Available: <https://www.ultralytics.com/pt/legal/enterprise-software-license>
- [11] F. Wu, R. Gazo, E. Haviarova, and B. Benes, "Wood identification based on longitudinal section images by using deep learning," *Wood Science and Technology*, no. 55, p. 553–563, Aug. 2021. [Online]. Available: <https://doi.org/10.1007/s00226-021-01261-1>
- [12] A. R. de Geus, S. F. d. Silva, A. B. Gontijo, F. O. Silva, M. A. Batista, and J. R. Souza, "An analysis of timber sections and deep learning for wood species classification," *Multimedia Tools and Applications*, vol. 79, no. 45, pp. 34 513–34 529, 2020. [Online]. Available: <https://doi.org/10.1007/s11042-020-09212-x>
- [13] J. Redmon and A. Farhadi, "Yolov3: An incremental improvement," 2018. [Online]. Available: <https://arxiv.org/abs/1804.02767>
- [14] A. Bochkovskiy, C.-Y. Wang, and H.-Y. M. Liao, "Yolov4: Optimal speed and accuracy of object detection," 2020. [Online]. Available: <https://arxiv.org/abs/2004.10934>
- [15] H. Zhang, M. Cisse, Y. N. Dauphin, and D. Lopez-Paz, "mixup: Beyond empirical risk minimization," 2018. [Online]. Available: <https://arxiv.org/abs/1710.09412>
- [16] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: A simple way to prevent neural networks from overfitting," *Journal of Machine Learning Research*, vol. 15, no. 56, pp. 1929–1958, 2014. [Online]. Available: <http://jmlr.org/papers/v15/srivastava14a.html>