

SEGMENTAÇÃO DE IMAGENS MACROSCÓPICAS DE MADEIRA DO BIOMA AMAZÔNICO

Laerte Menegol Ledur¹, Pedro Luiz de Paula Filho², Mariana Cabral Hetka Bczuska²

¹Universidade Tecnológica Federal do Paraná (UTFPR), Medianeira - PR, Brasil,
laerteledur@alunos.utfpr.edu.br

²Universidade Tecnológica Federal do Paraná (UTFPR), Medianeira - PR, Brasil

Resumo: O uso de modelo de segmentação para o processamento de imagens é uma possível alternativa para aprimorar a capacidade de modelos de classificação para reconhecimento florestal de espécies madeiráveis, tornando a fiscalização de cargas de madeira mais efetiva. O objetivo deste trabalho foi treinar e avaliar um modelo de segmentação para imagens macroscópicas de madeira provenientes de câmera celular. A arquitetura escolhida foi o YOLOv11, atingindo uma métrica de IoU de 0,95 e coeficiente Dice de 0,97 no conjunto de teste.

Palavras-chave: Reconhecimento florestal; espécies madeiráveis; segmentação de imagens; YOLOv11.

INTRODUÇÃO

As florestas desempenham um papel importante na regulação climática global e na manutenção dos ciclos hidrológicos, sendo responsáveis por influenciar significativamente os padrões de precipitação em regiões tropicais (Spracklen; Arnold; Taylor, 2012). Além de sua importância ecológica, esses ecossistemas possuem elevado valor econômico, especialmente no contexto da exploração madeireira.

Entretanto, a fiscalização da extração ilegal de madeira no bioma Amazônico enfrenta desafios estruturais, como a grande extensão territorial, limitações logísticas e a dificuldade de rastreamento da origem dos produtos florestais.

Um dos principais entraves nesse processo é a escassez de especialistas capacitados em anatomia da madeira, responsáveis por identificar espécies com base em características macroscópicas e microscópicas. Esse tipo de identificação exige treinamento especializado e experiência prática, tornando o processo demorado e pouco escalável (Souza et al., 2020).

Segundo Raven et al. (2014), o reconhecimento de espécies vegetais pode ser realizado a partir da observação de características estruturais, como padrões de fibras, porosidade e textura, que também estão presentes na madeira e podem ser exploradas em análises macroscópicas.

Sendo assim, o uso de técnicas de visão computacional e aprendizado profundo surge como uma alternativa promissora para automatizar o

reconhecimento de espécies de florestais madeiráveis.

Existem vários outros trabalhos abordando técnicas de reconhecimento de imagens em conjuntos de dados de imagens de macroscópica da madeira, como o de Ergun (2024), que tem foco em comparar múltiplas técnicas de aprendizado profundo para realizar o reconhecimento florestal da madeira. Também foi proposto por Herrera-Poyatos et al. (2024) um método de *deep learning* para classificação de espécies com imagens de câmera celular.

Porém, ao se utilizar essas imagens, além da madeira a ser reconhecida, existem vários elementos capturados que podem introduzir ruído na hora da classificação da espécie da amostra.

Então, este presente trabalho propõe o uso de uma etapa de segmentação para auxiliar o processamento das imagens capturadas por dispositivos móveis, com o intuito de recortar a imagem e reduzir o ruído na aplicação de modelos de classificação de espécies.

MATERIAL E MÉTODOS

Para a realização do presente trabalho, preparação do conjunto de dados, treinamento do modelo e avaliação do modelo resultante. A Figura 1 mostra o diagrama de etapas a serem seguidas.





Figura 1. Etapas do projeto.



O conjunto de dados selecionado contém imagens do corte transversal de 30 espécies florestais madeiráveis, totalizando 673 imagens de câmera celular, fornecidos pelo Grupo de Inteligência Computacional (GIC) da UTFPR. A Tabela 1 apresenta as espécies presentes no conjunto de dados e a quantidade de imagens de cada uma.

Tabela 1. Quantidade de imagens por espécie.

Espécie	Quantidade
<i>Apuleia leiocarpa</i>	21
<i>Aspidosperma desmanthum</i>	14
<i>Astronium lecointei</i>	20
<i>Bertholletia excelsa</i>	13
<i>Bowdichia nitida</i>	27
<i>Buchenavia oxycarpa</i>	20
<i>Calophyllum brasiliense</i>	58
<i>Cariniana micrantha</i>	61
<i>Caryocar villosum</i>	12
<i>Cedrela odorata</i>	16
<i>Clarisia racemosa</i>	19
<i>Couratari multiflora</i>	14
<i>Couratari stellata</i>	13
<i>Couratari tauari</i>	31
<i>Dinizia excelsa</i>	27
<i>Dipteryx odorata</i>	31
<i>Dipteryx sp.</i>	18
<i>Eperua oleifera</i>	16
<i>Handroanthus serratifolius</i>	15
<i>Handroanthus sp.</i>	12
<i>Hymenolobium excelsum</i>	12
<i>Luehea divaricata</i>	12
<i>Ocotea porosa</i>	36
<i>Peltogyne sp.</i>	58
<i>Pseudopiptadenia suaveolens</i>	12
<i>Qualea paraensis</i>	9
<i>Sextonia rubra</i>	14
<i>Vataireopsis sp.</i>	16
<i>Vitex megapotamica</i>	30
<i>Vochysia sp.</i>	16

O conjunto de dados possui imagens capturadas em diferentes condições, variando ângulo, fundo, fontes de iluminação e elementos obstrutivos, a fim de gerar uma variedade de possíveis cenários, gerando um modelo capaz de generalizar essas condições e ser efetivo em cenários de aplicação em campo.

É importante mencionar que existe um desbalanceamento entre a quantidade de imagens para as diferentes espécies no conjunto de dados, tendo espécies como a *Cariniana micrantha*, com 61 imagens, enquanto espécies como *Caryocar villosum* possuem apenas 9 imagens, podendo afetar o modelo resultante.

Foram aplicadas técnicas de *data augmentation* com o objetivo de aumentar a variabilidade dos dados e melhorar a capacidade de generalização do modelo, além de mitigar a escassez de instâncias em algumas espécies. Entre as transformações utilizadas estão rotações, espelhamentos e redimensionamento.

Para a etapa de treinamento do modelo, a arquitetura selecionada para a indução do modelo de segmentação foi o YOLOv11, da família YOLO (*You Only Look Once*), cujo a primeira arquitetura foi proposta por Redmon et al. (2016).

Para as diferentes etapas de treinamento, validação e teste do modelo, foi realizada uma divisão de 70% para a etapa de treinamento (471 imagens), 20% para a validação (134 imagens), e 10% para o teste (68 imagens).

O treinamento foi realizado utilizando pesos pré-treinados, aplicando a técnica de *transfer learning*. Nesse processo, as camadas iniciais da rede, responsáveis pela extração de características genéricas, como bordas, texturas e padrões visuais, foram mantidas, enquanto as camadas finais foram ajustadas ao domínio específico do problema. Essa abordagem reduz o tempo de treinamento e melhora a convergência do modelo. (Ultralytics, 2024).

Também foi aplicada a técnica de *Early Stopping*, em que se interrompe o treinamento de um modelo assim que a performance no conjunto de validação para de crescer, prevenindo que o modelo apenas memorize as imagens do treinamento e fique incapaz de segmentar de forma efetiva imagens novas (Ultralytics, 2024).

Por fim, utilizando o conjunto de teste, foi realizada a avaliação da performance do segmentador, através das métricas de IoU (*Intersection over Union*) e Dice, a fim de analisar a capacidade do modelo de rotular apenas pixels que realmente representam madeira.

A métrica de IoU, selecionada por ser a métrica mais utilizada para tarefas de segmentação, corresponde a razão entre a razão entre a área corretamente rotulada (interseção entre a predição e o rótulo real) e a área

total resultante da união entre ambas. A Equação 1 evidencia essa relação utilizando de operações sobre conjuntos.

$$IoU(P, G) = \frac{|P \cap G|}{|P \cup G|} \quad (1)$$

Já o coeficiente de Dice, mede a razão entre o dobro da área corretamente rotulada e a soma da do rótulo real e da predição do modelo. A Equação 2 formaliza essa relação e, por se tratar de uma métrica normalizada baseada na sobreposição entre conjuntos, seu valor também está restrito ao intervalo de 0 a 1.

$$Dice(P, G) = \frac{2|P \cap G|}{|P| + |G|} \quad (2)$$

O coeficiente de Dice é amplamente utilizado em tarefas de segmentação de imagens médicas, sendo adotado neste trabalho como uma métrica complementar ao IoU, por apresentar maior sensibilidade à sobreposição relativa entre regiões segmentadas, especialmente em casos de objetos de menor dimensão.

RESULTADOS E DISCUSSÃO

Após treinar e avaliar o modelo, na etapa de teste foram coletadas as métricas citadas anteriormente. Ao medir a métrica IoU, foi obtido um valor de 0,95, e a medição do coeficiente Dice resultou em 0,97.

O valor de IoU de 0,95 indica uma alta sobreposição entre as regiões preditas pelo modelo e as máscaras manualmente anotadas. Já o coeficiente Dice de 0,97 reforça a elevada similaridade espacial entre predição e anotação, sendo mais sensível à sobreposição em regiões menores.

A Figura 2 demonstra uma comparação entre a anotação manual feita por um ser humano e a predição do modelo, sobrepondo os dois para visualizar os falsos positivos e falsos negativos.




Figura 2. comparação entre predição e anotação humana.

Os resultados sugerem que o modelo é adequado para aplicações em campo, especialmente como etapa de pré-processamento para remoção de regiões não pertencentes à madeira. A alta concordância espacial implica que a maior parte da região útil é preservada após a aplicação da máscara, com perdas e inclusões indevidas restritas a regiões marginais.

A Figura 3 apresenta um exemplo do conjunto de teste, evidenciando que a aplicação da máscara de segmentação mantém a integridade da região de madeira, mesmo após o recorte.




Figura 3. Predição do modelo aplicado como máscara na imagem original.

Além disso, observou-se que, em amostras contendo rachaduras visíveis, o modelo frequentemente não as classifica como madeira, mesmo quando tais estruturas não foram explicitamente anotadas durante o processo de rotulação. A Figura 4 ilustra um exemplo em que uma rachadura é corretamente excluída da máscara final.




Figura 4. Comparação entre imagem original, anotação humana e máscara inferida.

Esse comportamento sugere uma capacidade de generalização do modelo, possivelmente associada à aprendizagem de padrões texturais e estruturais característicos da madeira.

CONCLUSÃO

O modelo de segmentação baseado na arquitetura YOLOv11 demonstrou um alto desempenho na geração de máscaras para recorte da região de madeira nas imagens originais, indicando seu potencial de aplicação em campo.

Os resultados obtidos sugerem que o modelo é capaz de preservar adequadamente a região da madeira, enquanto remove áreas não relacionadas, contribuindo para a redução de ruído nas entradas de modelos subsequentes.

Observou-se também um comportamento de generalização, evidenciado pela exclusão de imperfeições no processo de rotulagem, como rachaduras presentes em algumas amostras. Esse resultado indica que o modelo pode ter aprendido características estruturais da madeira, em vez de decorar as anotações fornecidas no conjunto de treinamento.

Para trabalhos futuros, sugere-se expandir esse conjunto de dados, a fim de mitigar o desbalanceamento entre espécies, possibilitando uma capacidade de generalização ainda maior. Além disso, ainda é necessário realizar a aplicação efetiva desse modelo dentro de um *pipeline* de classificação que ainda deverá ser avaliada.

AGRADECIMENTOS

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

REFERÊNCIAS

- ERGUN, H. Wood identification based on macroscopic images using deep and transfer learning approaches. *PeerJ*, 2024.
- HERRERA-POYATOS, D. et al. Deep learning methodology for the identification of wood species using high-resolution macroscopic images. In: 2024 INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN). IEEE, 2024.
- RAVEN, P. H.; EVERT, R. F.; EICHHORN, S. E. *Biologia Vegetal*. Guanabara Koogan, Rio de Janeiro, 2014.
- REDMON, J. et al. You only look once: unified, real-time object detection. In: IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2016.
- SOUZA, D. V. et al. An automatic recognition system of brazilian flora species based on textural features of macroscopic images of wood. *Wood Science and Technology*, Berlin, 2020.
- SPRACKLEN, D. V.; ARNOLD, S. R.; TAYLOR, C. M. Observations of increased tropical rainfall preceded by air passage over forests. *Nature*, 2012.
- ULTRALYTICS. Ultralytics glossary. 2024. Disponível em: <https://www.ultralytics.com/glossary>. Acesso em: 16 mar. 2026.