


A blue line drawing of the University of Paraná building facade, featuring a large portico with columns and a pediment. The text "UNIVERSIDADE DO PARANÁ" is visible on the pediment and the building's facade.

UNIVERSIDADE FEDERAL DO PARANÁ

MAURO ALESSANDRO KARASINSKI

ONDE ESTÃO AS PALMEIRAS NA AMAZÔNIA? SENSORIAMENTO REMOTO  
E INTELIGÊNCIA ARTIFICIAL APLICADOS À ANÁLISE ESPACIAL DA  
OCORRÊNCIA E DENSIDADE DE ESPÉCIES

CURITIBA

2025

MAURO ALESSANDRO KARASINSKI

ONDE ESTÃO AS PALMEIRAS NA AMAZÔNIA? SENSORIAMENTO  
REMOTO E INTELIGÊNCIA ARTIFICIAL APLICADOS À ANÁLISE ESPACIAL DA  
OCORRÊNCIA E DENSIDADE DE ESPÉCIES

Tese apresentada ao curso de Pós-Graduação em  
Engenharia Florestal, Setor de Ciências Agrárias,  
Universidade Federal do Paraná, como requisito parcial  
à obtenção de título de Doutor em Engenharia Florestal.

Orientadora: Profa. Dra. Ana Paula Dalla Corte

Coorientador: Prof. Dr. Evandro Orfanó Figueiredo

Coorientador: Prof. Dr. Eben North Broadbendt

CURITIBA

2025

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

Karasinski, Mauro Alessandro

Onde estão as palmeiras na Amazônia? Sensoriamento remoto e inteligência artificial aplicados à análise espacial da ocorrência e densidade de espécies / Mauro Alessandro Karasinski. - Curitiba, 2025.  
1 recurso on-line : PDF.

Orientadora: Profa. Dra. Ana Paula Dalla Corte

Coorientadores: Prof. Dr. Evandro Orfanó Figueiredo

Prof. Dr. Eben North Broadbendt

Tese (Doutorado) - Universidade Federal do Paraná, Setor de Ciências Agrárias, Programa de Pós-Graduação em Engenharia Florestal. Defesa: Curitiba, 07/07/2025.

1. Sensoriamento remoto - Amazônia. 2. Palmeira - Amazônia - Mapeamento. 3. Levantamentos florestais - Sensoriamento remoto. 4. Inteligência artificial. I. Dalla Corte, Ana Paula. II. Figueiredo, Evandro Orfanó. III. Broadbendt, Eben North. IV. Universidade Federal do Paraná, Setor de Ciências Agrárias. V. Título.

CDD – 621.3678

CDU – 528.8(811)

Bibliotecária: Berenice Rodrigues Ferreira – CRB 9/1160





MINISTÉRIO DA EDUCAÇÃO  
SETOR DE CIÊNCIAS AGRÁRIAS  
UNIVERSIDADE FEDERAL DO PARANÁ  
PRÓ-REITORIA DE PÓS-GRADUAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA  
FLORESTAL - 40001016015P0

## TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação ENGENHARIA FLORESTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **MAURO ALESSANDRO KARASINSKI**, intitulada: **Onde estão as palmeiras na Amazônia? Sensoriamento remoto e inteligência artificial aplicados à análise espacial da ocorrência e densidade de espécies**, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

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

CURITIBA, 07 de Julho de 2025.

Assinatura Eletrônica  
07/07/2025 18:09:07.0  
ANA PAULA DALLA CORTE  
Presidente da Banca Examinadora

Assinatura Eletrônica  
09/07/2025 18:13:12.0  
JORGE ANTONIO SILVA CENTENO  
Avaliador Externo (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica  
08/07/2025 10:39:51.0  
EVANDRO JOSÉ LINHARES FERREIRA  
Avaliador Externo (INSTITUTO NACIONAL DE PESQUISAS DA  
AMAZÔNIA)

Assinatura Eletrônica  
09/07/2025 10:17:09.0  
MATHEUS PINHEIRO FERREIRA  
Avaliador Externo (ESCOLA SUPERIOR DE AGRICULTURA - LUIZ DE  
QUEIROZ -USP)

Assinatura Eletrônica  
08/07/2025 10:56:48.0  
GUSTAVO MANZON NUNES  
Avaliador Externo (UNIVERSIDADE FEDERAL DE MATO GROSSO)



Sob a luz de **Jaci**, as palmeiras sussurram segredos antigos.  
Conta-se que, em tempos remotos, quando a floresta ainda aprendia a respirar, Tupã concedeu às terras da Amazônia plantas sagradas, cada uma carregando um dom para os povos que ali viviam.

Foi então que nasceu o **Patauá**, cujos frutos, ricos e viscosos, eram lágrimas de Tupã derramadas sobre a terra para nutrir seus filhos. Ao lado dele, o **Açaí**, presente de Iaçã, a jovem que chorou por sua filha perdida, e cuja dor transformou-se no fruto que alimenta e fortalece os guerreiros.

Nas margens dos rios, ergueu-se o **Paxiuba**, a palmeira de raízes que caminham, plantada sobre as cinzas de Jurupari, o espírito da ordem e da transformação. Enquanto isso, do Ocidente ao Oriente, do Norte à Mata Atlântica, passando pelo coração do Cerrado, o **Babaçu** espalhava suas sementes como estrelas caídas, ofertando sustento às mulheres que guardavam seus segredos em suas cascas duras.

Dos interiores silvestres do Norte, surgiu o **Urucuri**, cujas folhas, ao serem tocadas pelo vento, entoavam cânticos para os ancestrais. E foi entre espinhos que o **Tucumã** brotou, lembrando que da resistência nasce a fartura, pois é na casca dura que se esconde o fruto dourado.

Nas sombras úmidas do sub-bosque, onde a luz se filtra entre folhas grossas, nasceu o **Murumuru**, guardião do silêncio da floresta, seus espinhos protegem um segredo: a manteiga branca e curativa, dom de Tupã às curandeiras, para que aliviem dores e cicatrizem as feridas do corpo e da alma.

Nos leitos escuros dos igapós, quando a cheia cobre as raízes e o silêncio reina sob as águas, emergiu o **Jauari**. Suas raízes mergulham como serpentes sagradas, e seus frutos flutuam como oferendas, nutrindo os peixes e os povos que vivem com os ciclos da inundação.

Quando o céu se tingiu de roxo profundo, Tupã moldou a **Bacaba** para lembrar os crepúsculos da floresta. De sua polpa escura extrai-se o vinho espesso dos anciãos, bebida dos sábios que, ao redor da fogueira, mantêm viva a memória dos que vieram antes.

E do encontro entre o sol e as águas nasceu o **Buriti**, palmeira da luz líquida. Suas folhas douradas refletem os raios de Jaci, enquanto seus frutos, cor de fogo, trazem a promessa da vida que renasce. Ao seu lado, ergue-se a **Buritirana**, coberta de espinhos como guardião do sagrado, protegendo-o com sua presença discreta. Juntas, sustentam pássaros, gentes e espíritos viajantes pelos caminhos inundados da floresta.

Entre folhas plumosas e tronco altivo, surgiu o **Cocão**. De suas amêndoas brotava um óleo espesso, capaz de nutrir corpos e acender a chama das aldeias, dom fecundo deixado por Tupã para sustentar a força dos que habitam a mata.

Por fim, quando a noite cobriu a floresta com seu manto estrelado, Jaci desceu dos céus e tocou a terra, dando vida ao **Inajá**, a palmeira do fogo sagrado, cujos frutos queimam como o próprio sol e aquecem os corações dos que honram a natureza.

Assim, sob a proteção de Jaci e Tupã, as palmeiras cresceram, testemunhas vivas da sabedoria indígena. Seus nomes ecoam na mata, contando histórias de sobrevivência, resistência e harmonia com a floresta.

Mauro A. Karasinski

## RESUMO

A floresta amazônica abriga uma notável diversidade de palmeiras com relevância ecológica, econômica e sociocultural, cuja distribuição espacial e densidade ainda são pouco conhecidas devido à complexidade do ambiente e às limitações logísticas da coleta em campo. Esta tese estruturou-se em três capítulos inter-relacionados que investigam, por meio de geotecnologias e inteligência artificial, estratégias para mapear e modelar a ocorrência de palmeiras amazônicas em larga escala. No primeiro capítulo, avaliou-se o desempenho do modelo de deep learning YOLOv10x para detecção automática de 14 espécies de palmeiras em imagens RGB obtidas por drones em 47 locais da Amazônia ocidental, destacando-se o modelo global com precisão média de (mAP) de 80% e elevada capacidade de generalização entre regiões (F1-score = 79%), regiões com maior número de imagem e indivíduos, Regiões com maior número de imagens e indivíduos, como Baixo Acre, apresentaram os melhores desempenhos (mAP > 0,90), enquanto áreas com amostragem limitada, como Juruá e Sul do Amazonas, obtiveram mAPs abaixo de 0,37. O segundo capítulo investigou o impacto da sazonalidade sobre a acurácia do modelo, comparando períodos seco e chuvoso no estado do Acre. Os resultados indicaram variações interespecíficas relacionadas à fenologia e à visibilidade no dossel, em que o período chuvoso apresentou desempenho superior ao seco, evidenciando a importância do estabelecimento de um calendário de coleta das imagens, a fim de considerar aspectos ecológicos como e operacionais na coleta e no treinamento dos modelos. Por fim, o terceiro capítulo integrou as detecções obtidas com YOLOv10x a variáveis ambientais para modelar e espacializar a densidade das espécies com *Random Forest*, utilizando abordagem bootstrap. Os modelos apresentaram desempenho preditivo variável entre as espécies, coeficientes de determinação ( $R^2$ ) entre 0,45 e 0,85. As covariáveis de maior importância foram precipitações máxima e mínima, as temperaturas máxima e mínima, a longitude, a latitude, a elevação e o índice topográfico de umidade (TWI). Os mapas gerados revelaram a preferência de algumas espécies, como *Mauritia flexuosa* (buriti), *Astrocaryum aculeatum* (tucumã), *Euterpe precatoria* (açaí) e *Oenocarpus bataua* (patauá), por áreas de baixo e maior umidade, enquanto outras, como *Attalea maripa* (inajá), se distribuíram em terrenos mais elevados e bem drenados. Esses padrões específicos de ocorrência podem servir de base para a identificação de áreas prioritárias para cadeias produtivas da bioeconomia amazônica. Os resultados demonstram o potencial da combinação entre sensoriamento remoto, aprendizado profundo e modelagem ambiental como ferramenta estratégica para monitoramento, planejamento territorial e valorização da sociobiodiversidade na Amazônia.

**Palavras-chave:** Palmeiras amazônicas, Detecção automática, Deep learning, YOLOv10x Sensoriamento remoto, Modelagem ambiental, Bioeconomia

## ABSTRACT

The Amazon rainforest harbors a remarkable diversity of palm species with ecological, economic, and sociocultural relevance, whose spatial distribution and density remain poorly understood due to the complexity of the environment and logistical limitations of field sampling. This dissertation is structured into three interrelated chapters that investigate, through geotechnologies and artificial intelligence, strategies to map and model the occurrence of Amazonian palms at a large scale. In the first chapter, the performance of the deep learning model YOLOv10x was evaluated for the automatic detection of 14 palm species in RGB images captured by drones across 47 locations in the western Amazon. Regions with a larger number of images and individuals, such as Baixo Acre, achieved the best performance (mAP > 0.90), while areas with limited sampling, such as Juruá and southern Amazonas, had mAP values below 0.37. However, the global model stood out with a mean Average Precision (mAP) of 80% and high generalization capacity across regions (F1-score = 79%). The second chapter investigated the impact of seasonality on model accuracy by comparing dry and rainy periods in the state of Acre. The results indicated interspecies variations related to phenology and canopy visibility, with the rainy season showing better performance than the dry season. This highlights the importance of establishing an image acquisition calendar that considers both ecological and operational aspects during data collection and model training. Finally, the third chapter integrated the detections obtained with YOLOv10x and environmental variables to model and spatialize species density using the Random Forest algorithm, adopting a bootstrap approach. The models exhibited varying predictive performance among species, with coefficients of determination ( $R^2$ ) ranging from 0.45 to 0.85. The most important covariates were maximum and minimum precipitation, maximum and minimum temperature, longitude, latitude, elevation, and the Topographic Wetness Index (TWI). The generated maps revealed specific habitat preferences for some species, such as *Mauritia flexuosa* (buriti), *Astrocaryum aculeatum* (tucumã), *Euterpe precatoria* (açaí), and *Oenocarpus bataua* (patauá), which favored low-lying and wetter areas, while others, such as *Attalea maripa* (inajá), were distributed in higher and better-drained terrains. These specific occurrence patterns may serve as a basis for identifying priority areas for sustainable value chains within the Amazon bioeconomy. The results demonstrate the potential of combining remote sensing, deep learning, and environmental modeling as a strategic tool for monitoring, territorial planning, and the enhancement of sociobiodiversity in the Amazon.

**Keywords:** Amazonian palms, Automatic detection, Deep learning, YOLOv10x, Remote sensing, Environmental modeling, Bioeconomy.



## LISTA DE FIGURAS

|                                                                                                                                                            |    |
|------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| FIGURA 1 - <i>Astrocaryum aculeatum</i> (TUCUMÃ) OBSERVADO A PARTIR DO SOLO<br>(ESQUERDA, FOTO: RUBEM D. LAYME) E POR IMAGEM AÉREA<br>(DIREITA). .....     | 30 |
| FIGURA 2 - <i>Attalea butyracea</i> (JACI) OBSERVADO A PARTIR DO SOLO (ESQUERDA,<br>FOTO: ARTURO C. MENDOZA) E POR IMAGEM AÉREA (DIREITA).<br>.....        | 31 |
| FIGURA 3 - <i>Astrocaryum jauari</i> (JAUARI) OBSERVADO A PARTIR DO SOLO<br>(ESQUERDA, FOTO: PEDRO ALONSO) E POR IMAGEM AÉREA<br>(DIREITA). .....          | 32 |
| FIGURA 4 - <i>Attalea maripa</i> (INAJÁ) OBSERVADO A PARTIR DO SOLO (ESQUERDA,<br>FOTO: RICH HOYER) E POR IMAGEM AÉREA (DIREITA). .....                    | 33 |
| FIGURA 5 - <i>Attalea phalerata</i> (URUCURI) OBSERVADO A PARTIR DO SOLO<br>(ESQUERDA, FOTO: ALFREDO GUTIERREZ DIPAZ) E POR IMAGEM<br>AÉREA (DIREITA)..... | 34 |
| FIGURA 6 - <i>Attalea speciosa</i> (BABAÇU) OBSERVADO A PARTIR DO SOLO<br>(ESQUERDA, FOTO: LUCAS C. MARINHO) E POR IMAGEM AÉREA<br>(DIREITA). .....        | 36 |
| FIGURA 7 - <i>Attalea tessmannii</i> (COCÃO) OBSERVADO A PARTIR DO SOLO<br>(ESQUERDA, FOTO: EVANDRO FERREIRA) E POR IMAGEM AÉREA<br>(DIREITA). .....       | 37 |
| FIGURA 8 - <i>Astrocaryum ulei</i> (MURUMURU) OBSERVADO A PARTIR DO SOLO<br>(ESQUERDA, FOTO: VANESSA FLORES) E POR IMAGEM AÉREA<br>(DIREITA). .....        | 38 |
| FIGURA 9 - <i>Euterpe precatoria</i> (AÇAÍ SOLTEIRO) OBSERVADO A PARTIR DO SOLO<br>(ESQUERDA, FOTO: A. ARAUJO) E POR IMAGEM AÉREA (DIREITA).<br>.....      | 39 |
| FIGURA 10 - <i>Mauritiella armata</i> (BURITIRANA) OBSERVADO A PARTIR DO SOLO<br>(ESQUERDA, FOTO: NILS SERVIENTIS) E POR IMAGEM AÉREA<br>(DIREITA). .....  | 40 |
| FIGURA 11 - <i>Mauritia flexuosa</i> (BURITI) OBSERVADO A PARTIR DO SOLO<br>(ESQUERDA, FOTO: MAURO A. KARASINSKI) E POR IMAGEM<br>AÉREA (DIREITA).....     | 41 |

|                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                   |    |
|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| FIGURA 12 - <i>Oenocarpus bacaba</i> (BACABA) OBSERVADO A PARTIR DO SOLO (ESQUERDA, FOTO: RENATA XAVIER) E POR IMAGEM AÉREA (DIREITA). .....                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                      | 42 |
| FIGURA 13 - <i>Oenocarpus bataua</i> (PATAUÁ) OBSERVADO A PARTIR DO SOLO (ESQUERDA, FOTO: GUILLAUME LÉOTARD) E POR IMAGEM AÉREA (DIREITA).....                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                    | 44 |
| FIGURA 14 - <i>Socratea exorrhiza</i> (PAXIUBA) OBSERVADO A PARTIR DO SOLO (ESQUERDA, FOTO: DESERT MAX) E POR IMAGEM AÉREA (DIREITA). .....                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                       | 45 |
| FIGURA 15 - LOCALIZAÇÃO DA ÁREA DE ESTUDO. EM VERDE ÁREA OCUPADA POR FLORESTA, EM AMARELO ÁREA DE TRANSIÇÃO DE FLORESTA PARA CERRADO, NOS ESTADOS DA AMAZÔNIA LEGAL. OS PONTOS REPRESENTAM CADA SÍTIO NOS QUAIS AS IMAGENS FORAM OBTIDAS. ....                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                    | 58 |
| FIGURA 16 ETAPAS DE PRÉ-PROCESSAMENTO DAS IMAGENS CAPTURADAS POR RPA. (a) <i>TILES</i> COM DISTORÇÕES, BAIXA QUALIDADE OU LOCALIZADOS NAS BORDAS DAS ORTOFOTOS FORAM DESCARTADOS. (b) COPAS DEMARCADAS NO <i>TILE</i> . ....                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                      | 61 |
| FIGURA 17 - FORMAÇÃO DO <i>DATASET</i> UTILIZADO PARA O ESTUDO. (A) DISTRIBUIÇÃO DOS DADOS POR ESPÉCIES DE PALMEIRAS ESTUDADAS E POR REGIÃO. (B) RELAÇÃO DA OCORRÊNCIA DAS ESPÉCIES NAS DIFERENTES REGIÕES ILUSTRADA POR UM DIAGRAMA DE SANKEY, EVIDENCIANDO A CONEXÃO ENTRE AS ESPÉCIES E SUAS RESPECTIVAS REGIÕES GEOGRÁFICAS. aa14 – TUCUMÃ ( <i>Astrocaryum aculeatum</i> ), ab10 – JACI ( <i>Attalea butyracea</i> ), aj82 – JAUARI ( <i>Astrocaryum jauari</i> ), am16 – INAJÁ ( <i>Attalea maripa</i> ), ap12 – URUCURI ( <i>Attalea phalerata</i> ), as48 – BABAÇU ( <i>Attalea speciosa</i> ), at34 – COCÃO ( <i>Attalea tessmannii</i> ), au13 – MURUMURU ( <i>Astrocaryum ulei</i> ), ep01 – AÇAÍ SOLTEIRO ( <i>Euterpe precatoria</i> ), ep35 – AÇAÍ PRODUTIVO ( <i>Euterpe precatoria</i> ), se04 – PAXIUBA ( <i>Socratea exorrhiza</i> ), ma79 – BURITIRANA ( <i>Mauritiella armata</i> ), mf09 – BURITI ( <i>Mauritia flexuosa</i> ), ob70 – BACABA ( <i>Oenocarpus bacaba</i> ), ob19 – PATAUÁ ( <i>Oenocarpus bataua</i> ). .... | 63 |

|                                                                                                                                                                                                                                                                                                                                                                                                                                                                                  |    |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| FIGURA 18 - DEMARCAÇÃO DAS COPAS INDIVIDUAIS DE PALMEIRAS NAS IMAGENS, EXEMPLO PARA <i>E. precatoria</i> . ( $B_x$ , $B_y$ ) REPRESENTAM AS COORDENADAS X E Y DO CENTRO DA CAIXA DELIMITADORA; $w$ REPRESENTA A LARGURA E $h$ A ALTURA DA CAIXA DELIMITADORA.....                                                                                                                                                                                                                | 64 |
| FIGURA 19 - CODIFICAÇÃO DO BANCO DE DADOS DE IMAGENS. CADA IMAGEM “.jpg” ESTÁ ACOMPANHADA DE UM ARQUIVO DE ANOTAÇÕES “.txt” NO FORMATO ADEQUANDO PARA YOLO.....                                                                                                                                                                                                                                                                                                                  | 64 |
| FIGURA 20 - CURVAS DE APRENDIZADO OBTIDAS POR MEIO DE VALIDAÇÃO CRUZADA ( $k=3$ ) AO LONGO DE 100 ITERAÇÕES, DEMONSTRANDO A EVOLUÇÃO DO MAP PARA CADA UMA DAS SETE REGIÕES AVALIADAS E PARA O CONJUNTO GLOBAL DE DADOS. ....                                                                                                                                                                                                                                                     | 71 |
| FIGURA 21 - MATRIZES DE CONFUSÃO PARA O MODELO GLOBAL APLICADO AO CONJUNTO DE TESTE. (a) CONSIDERA TODAS AS CLASSES, SEM RESTRIÇÃO GEOGRÁFICA, COM LIMIAR DE CONFIANÇA ( <i>CONFIDENCE THRESHOLD</i> ) DE 0,01; (b) APLICA RESTRIÇÕES GEOGRÁFICAS, ASSUMINDO QUE DETERMINADAS ESPÉCIES NÃO OCORREM SIMULTANEAMENTE EM ALGUMAS REGIÕES, COM <i>CONFIDENCE THRESHOLD</i> DE 0,01; (c) CONSIDERA RESTRIÇÕES GEOGRÁFICAS E UTILIZA UM LIMIAR DE CONFIANÇA MAIS RIGOROSO (0,25). .... | 78 |
| FIGURA 22 - EXEMPLO DE DETECÇÕES COM YOLOV10X, PARA AS 14 ESPÉCIES DE PALMEIRAS DISTRIBUÍDAS NAS 7 REGIÕES DA ÁREA DE ESTUDO. ....                                                                                                                                                                                                                                                                                                                                               | 81 |
| FIGURA 23 - LOCALIZAÇÃO DA ÁREA DE ESTUDO. EM VERDE ÁREA OCUPADA POR FLORESTA, EM AMARELO ÁREA DE TRANSIÇÃO DE FLORESTA PARA CERRADO, NOS ESTADOS DA AMAZÔNIA LEGAL. ....                                                                                                                                                                                                                                                                                                        | 88 |
| FIGURA 24 - PRECIPITAÇÃO MÉDIA MENSAL NOS ÚLTIMOS 10 ANOS PARA O VALE DO ACRE COM BASE NAS ESTAÇÕES METEOROLÓGICAS DE RIO BRANCO E EPITACIOLÂNDIA (INMET, 2025).....                                                                                                                                                                                                                                                                                                             | 89 |
| FIGURA 25 - CURVA DE APRENDIZAGEM PARA OS PERÍODOS SECO E CHUVOSO, COM A MÉDIA DOS CINCO <i>FOLDS</i> . AS CURVAS INDIVIDUAIS,                                                                                                                                                                                                                                                                                                                                                   |    |

|                                                                                                                                                                                                                                                                                                                                                                                                                                                       |     |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| EXIBIDAS AO FUNDO COM MENOR OPACIDADE, ILUSTRAM A VARIAÇÃO ENTRE OS <i>FOLDS</i> . ....                                                                                                                                                                                                                                                                                                                                                               | 93  |
| FIGURA 26 - DISTRIBUIÇÃO DAS DIFERENÇAS DE DESEMPENHO (PRECISÃO, RECALL E MAP) ENTRE OS PERÍODOS SECO E CHUVOSO POR ESPÉCIE, OBTIDA POR BOOTSTRAP PAREADO COM 10.000 REAMOSTRAGENS. CADA <i>BOXPLOT</i> REPRESENTA A DISTRIBUIÇÃO DAS DIFERENÇAS AMOSTRADAS (SECO – CHUVOSO), PERMITINDO VISUALIZAR A DIREÇÃO E A MAGNITUDE DA DIFERENÇA PARA CADA ESPÉCIE. VALORES ACIMA DE ZERO INDICAM MELHOR DESEMPENHO NO PERÍODO SECO; ABAIXO, NO CHUVOSO. .... | 96  |
| FIGURA 27 – DISTRIBUIÇÃO MENSAL DA FREQUÊNCIA E INTENSIDADE DOS VENTOS POR DIREÇÃO (INMET, 2025). AS CORES INDICAM FAIXAS DE VELOCIDADE (m/s), E O TAMANHO DOS SETORES REPRESENTA A FREQUÊNCIA DOS VENTOS EM CADA DIREÇÃO. ....                                                                                                                                                                                                                       | 101 |
| FIGURA 28 - COMPARAÇÃO DE IMAGENS NO PERÍODO SECO E CHUVOSO. (e) DESTAQUE PARA A PALMEIRA DE <i>Euterpe precatoria</i> Mart. SEM CACHO, (f) DESTAQUE PARA <i>Euterpe precatoria</i> Mart. COM CACHO. ....                                                                                                                                                                                                                                             | 103 |
| FIGURA 29 - FLUXO METODOLÓGICO PARA ESTIMATIVA DA DENSIDADE DE PALMEIRAS, ILUSTRANDO A EXTRAÇÃO DAS VARIÁVEIS PREDITORAS AMBIENTAIS E O PROCESSO DE MODELAGEM UTILIZADO PARA GERAR AS ESTIMATIVAS ESPACIAIS DE DENSIDADE. ....                                                                                                                                                                                                                        | 110 |
| FIGURA 30 - LOCALIZAÇÃO DA ÁREA DE ESTUDO. EM VERDE ÁREA OCUPADA PELA FLORESTA AMAZÔNICA, EM AMARELO ÁREA DE TRANSIÇÃO DE FLORESTA PARA CERRADO, NOS ESTADOS DA AMAZÔNIA LEGAL. A ÁREA APROXIMADA DETALHA A MALHA DAS DENSIDADES PREDITAS PELO YOLOV10X ....                                                                                                                                                                                          | 111 |
| FIGURA 31 - CLASSIFICAÇÃO FUNCIONAL DE PALMEIRAS AMAZÔNICAS EM QUATRO CATEGORIAS PRINCIPAIS DE USO EM DIFERENTES CADEIAS PRODUTIVAS: ALIMENTÍCIOS, BIOCOMBUSTÍVEIS,                                                                                                                                                                                                                                                                                   |     |



|                                                                                       |     |
|---------------------------------------------------------------------------------------|-----|
| COSMÉTICOS E OUTROS COM BASE EM SUA INSERÇÃO EM<br>DIFERENTES CADEIAS PRODUTIVAS..... | 113 |
|---------------------------------------------------------------------------------------|-----|

|                                                                                                                                                                                                                                                                                                                                                                                                                                         |     |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| FIGURA 32 - MAPAS TEMÁTICOS DE VARIÁVEIS AMBIENTAIS UTILIZADAS NA<br>MODELAGEM DA DENSIDADE DE PALMEIRAS. (a) TIPOS DE<br>VEGETAÇÃO, CONFORME CLASSIFICAÇÃO FISIONÔMICO-<br>AMBIENTAL ADAPTADA DA UNESCO (IBGE, 2023). (b) CLASSES DE<br>SOLOS SEGUNDO O SISTEMA BRASILEIRO DE CLASSIFICAÇÃO DE<br>SOLOS (SiBCS) (IBGE, 2023). (c) MODELO TOPOGRÁFICO<br>DERIVADO DO SRTM, REPRESENTANDO OS PADRÕES DE RELEVO<br>DA ÁREA DE ESTUDO..... | 114 |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|

|                                                                                                                                                                                                                                                                                                                                                                                                                                                                       |     |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| FIGURA 33 - MAPAS TEMÁTICOS DAS VARIÁVEIS CLIMÁTICAS DE<br>PRECIPITAÇÃO UTILIZADAS NA MODELAGEM DA DENSIDADE DE<br>PALMEIRAS. (a) PRECIPITAÇÃO MÍNIMA MÉDIA MENSAL (mm). (b)<br>PRECIPITAÇÃO MÉDIA MENSAL (mm). (c) PRECIPITAÇÃO MÁXIMA<br>MÉDIA MENSAL (mm). VALORES DERIVADOS DO CONJUNTO DE<br>DADOS CHIRPS ( <i>CLIMATE HAZARDS GROUP INFRARED<br/>PRECIPITATION WITH STATION DATA</i> ), COM RESOLUÇÃO ESPACIAL<br>DE 0.05° E SÉRIE TEMPORAL DE 1981 A 2025..... | 115 |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|

|                                                                                                                                                                                                                                                                                                                                                                                                                                                                                               |     |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| FIGURA 34 - MAPAS TEMÁTICOS DAS VARIÁVEIS CLIMÁTICAS DE<br>TEMPERATURA UTILIZADAS NA MODELAGEM DA DENSIDADE DE<br>PALMEIRAS. (a) TEMPERATURA MÍNIMA MÉDIA MENSAL (°C). (b)<br>TEMPERATURA MÉDIA MENSAL (°C). (c) TEMPERATURA MÁXIMA<br>MÉDIA MENSAL (°C). VALORES DERIVADOS DO CONJUNTO DE<br>DADOS CHIRTS-DAILY ( <i>CLIMATE HAZARDS INFRARED<br/>TEMPERATURE WITH STATIONS – DAILY</i> ), COM RESOLUÇÃO<br>ESPACIAL DE 0.05° E SÉRIE TEMPORAL COMPREENDENDO OS<br>ANOS DE 1983 A 2016. .... | 116 |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|

|                                                                                                                                                                                                                                                                                                                      |  |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--|
| FIGURA 35 - MAPAS TEMÁTICOS DE HIDROGRAFIA UTILIZADOS NA<br>MODELAGEM DA DENSIDADE DE PALMEIRAS. (a) REDE<br>HIDROGRÁFICA DETALHADA DA ÁREA DE ESTUDO,<br>DESTACANDO OS PRINCIPAIS RIOS DA REGIÃO E SEUS<br>AFLUENTES. (b) ÍNDICE DE UMIDADE TOPOGRÁFICA (TWI),<br>DERIVADO DE DADOS DO SRTM E CALCULADO COM BASE NA |  |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--|

|                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                |     |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| DECLIVIDADE E ACUMULAÇÃO DE FLUXO. (c) DELIMITAÇÃO DAS BACIAS HIDROGRÁFICAS PRESENTES NA ÁREA DE ESTUDO (ANA, 2025).....                                                                                                                                                                                                                                                                                                                                                                                       | 117 |
| FIGURA 36 - DISTRIBUIÇÃO DAS PALMEIRAS NA REGIÃO DE XAPURI, ACRE. (a) ORTOFOTO DA ÁREA DE ESTUDO. (b) MAPA TEMÁTICO DE ALTIMETRIA E PADRÃO ESPACIAL DAS ESPÉCIES ESTUDADAS. ....                                                                                                                                                                                                                                                                                                                               | 122 |
| FIGURA 37 - RELAÇÃO ENTRE OS VALORES OBSERVADOS E PREDITOS DE DENSIDADE PARA 14 ESPÉCIES DE PALMEIRAS AMAZÔNICAS, COM BASE EM MODELOS <i>RANDOM FOREST</i> . CADA PONTO REPRESENTA UMA CÉLULA DE VALIDAÇÃO (1 ha), E A LINHA TRACEJADA INDICA A CORRESPONDÊNCIA PERFEITA (1:1). OS MODELOS FORAM AVALIADOS POR MEIO DE VALIDAÇÃO COM BOOTSTRAP (N = 100), E OS GRÁFICOS APRESENTAM OS COEFICIENTES DE DETERMINAÇÃO (R <sup>2</sup> ), VIÉS MÉDIO (BIAS) E ERRO QUADRÁTICO MÉDIO (RMSE) PARA CADA ESPÉCIE. .... | 124 |
| FIGURA 38 - IMPORTÂNCIA RELATIVA DAS VARIÁVEIS AMBIENTAIS UTILIZADAS NA MODELAGEM DA DENSIDADE DE PALMEIRA PELO <i>RANDOM FOREST</i> . OS VALORES REPRESENTAM A MÉDIA DA IMPORTÂNCIA DAS VARIÁVEIS AO LONGO DE 100 ITERAÇÕES DE BOOTSTRAP. AS VARIÁVEIS MAIS RELEVANTES INCLUÍRAM PRECIPITAÇÃO MÍNIMA, ÍNDICE TOPOGRÁFICO DE UMIDADE (TWI), ELEVACÃO E LATITUDE, INDICANDO A INFLUÊNCIA DE FATORES CLIMÁTICOS E TOPOGRÁFICOS NA DISTRIBUIÇÃO DAS ESPÉCIES. ....                                                | 125 |
| FIGURA 39 - DISTRIBUIÇÃO DA DENSIDADE DAS ESPÉCIES DE PALMEIRAS QUE OCORREM NO ESTADO DO ACRE COM POTENCIAL DE UTILIZAÇÃO NA INDÚSTRIA ALIMENTÍCIA. ....                                                                                                                                                                                                                                                                                                                                                       | 126 |
| FIGURA 40 - DISTRIBUIÇÃO DA DENSIDADE DAS ESPÉCIES DE PALMEIRAS QUE OCORREM NO ESTADO DO ACRE COM POTENCIAL PARA A PRODUÇÃO DE BIOCOMBUSTÍVEIS. ....                                                                                                                                                                                                                                                                                                                                                           | 127 |

|                                                                                                                                                                |     |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| FIGURA 41 - DISTRIBUIÇÃO DA DENSIDADE DAS ESPÉCIES DE PALMEIRAS QUE OCORREM NO ESTADO DO ACRE COM POTENCIAL PARA A UTILIZAÇÃO NA INDÚSTRIA DE COSMÉTICOS. .... | 128 |
| FIGURA 42 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE <i>Astrocaryum aculeatum</i> (aa14) NO ESTADO DO ACRE. ....                                 | 149 |
| FIGURA 43 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE <i>attalea butyracea</i> (ab10) NO ESTADO DO ACRE. ....                                     | 150 |
| FIGURA 44 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE <i>Attalea maripa</i> (am16) NO ESTADO DO ACRE. ....                                        | 151 |
| FIGURA 45 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE <i>Attalea phalerata</i> (ap12) NO ESTADO DO ACRE. ....                                     | 152 |
| FIGURA 46 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE <i>Astrocaryum ulei</i> (au13) NO ESTADO DO ACRE. ....                                      | 153 |
| FIGURA 47 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE <i>Euterpe precatoria</i> (ep01 E ep35) NO ESTADO DO ACRE. ....                             | 154 |
| FIGURA 48 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE <i>Mauritia flexuosa</i> (mf09) no ESTADO DO ACRE. ....                                     | 155 |
| FIGURA 49 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE <i>Oenocarpus bataua</i> (ob19) no ESTADO DO ACRE. ....                                     | 156 |
| FIGURA 50 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE <i>Socratea exorrhiza</i> (se04) NO ESTADO DO ACRE. ....                                    | 157 |
| FIGURA 51 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE <i>Attalea speciosa</i> (as48) NO ESTADO DE RONDÔNIA. ....                                  | 158 |
| Figura 52 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE <i>Mauritiella armata</i> (ma79) NO ESTADO DE RONDÔNIA. ....                                | 159 |
| Figura 53 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE <i>Astrocaryum jauari</i> (aj82) NO ESTADO DE RORAIMA. ....                                 | 160 |
| Figura 54 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE <i>Oenocarpus bacaba</i> (ob70) NO ESTADO DE RORAIMA. ....                                  | 161 |

## LISTA DE TABELAS

|                                                                                                                                                                                                                                                                                                             |     |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| TABELA 1 - AGRUPAMENTO DO CONJUNTO DE DADOS POR REGIÃO. ....                                                                                                                                                                                                                                                | 62  |
| TABELA 2 – IDENTIFICAÇÃO DAS ESPÉCIES NA ÁREA DE ESTUDO .....                                                                                                                                                                                                                                               | 62  |
| TABELA 3 - CONFIGURAÇÃO DE TREINAMENTO PARA O MODELO YOLOV10X<br>PARA O PERÍODO SECO E CHUVOSO (EXEMPLO PARA <i>FOLD1</i> ). ...                                                                                                                                                                            | 66  |
| TABELA 4 - TEMPO MÉDIO DE TREINAMENTO E VALIDAÇÃO PARA AS SETE<br>REGIÕES E PARA AS REGIÕES AGRUPADAS. ....                                                                                                                                                                                                 | 70  |
| TABELA 5 - DESEMPENHO DO YOLOV10X NA DETECÇÃO DE 14 ESPÉCIES DE<br>PALMEIRAS EM DIFERENTES SÍTIOS NA FLORESTA AMAZÔNICA.<br>NÚMERO DE IMAGENS, NÚMERO DE INDIVÍDUOS E PRECISÃO<br>MÉDIA (MAP) NO PROCESSO DE VALIDAÇÃO CRUZADA COM K=3,<br>COM LIMIAR DE CONFIANÇA DE 0,25 ( <i>THRESHOLD</i> = 0,25). .... | 73  |
| TABELA 6 - MÉTRICAS UTILIZADAS NA AVALIAÇÃO DO YOLOV10X PARA OS<br>PERÍODOS SECOS E CHUVOSOS NO VALE DO ACRE. ....                                                                                                                                                                                          | 91  |
| TABELA 7 - RESULTADOS DA APRENDIZAGEM DO MODELO CONSIDERANDO AS<br>ESTAÇÕES SECAS E CHUVOSAS. ....                                                                                                                                                                                                          | 95  |
| TABELA 8 - DIFERENÇA MÉDIA ENTRE OS PERÍODOS SECO E CHUVOSO POR<br>ESPÉCIE E MÉTRICA, COM INTERVALO DE CONFIANÇA DE 95%<br>( <i>BOOTSTRAP</i> PAREADO) .....                                                                                                                                                | 97  |
| TABELA 9 - ESTATÍSTICAS DESCRITIVAS DE DENSIDADE E MORFOMETRIA DE<br>14 ESPÉCIES DE PALMEIRAS AMAZÔNICAS DETECTADAS EM<br>ORTOFOTOS RGB OBTIDAS POR DRONES, UTILIZANDO O<br>MODELO YOLOV10X. ....                                                                                                           | 121 |

## SUMÁRIO

|          |                                                                          |           |
|----------|--------------------------------------------------------------------------|-----------|
| <b>1</b> | <b>CONTEXTUALIZAÇÃO.....</b>                                             | <b>21</b> |
| 1.1      | ESTRUTURA DA TESE .....                                                  | 23        |
| <b>2</b> | <b>OBJETIVOS .....</b>                                                   | <b>25</b> |
| 2.1      | OBJETIVO GERAL.....                                                      | 25        |
| 2.2      | OBJETIVOS ESPECÍFICOS .....                                              | 25        |
| <b>3</b> | <b>REVISÃO DE LITERATURA .....</b>                                       | <b>26</b> |
| 3.1      | PRODUTOS FLORESTAIS NÃO MADEIREIROS .....                                | 26        |
| 3.2      | PALMEIRAS .....                                                          | 27        |
| 3.2.1    | <i>Astrocaryum aculeatum</i> G. Mey. ....                                | 29        |
| 3.2.2    | <i>Attalea butyracea</i> (Mutis ex L.f.) Wess.Boer .....                 | 30        |
| 3.2.3    | <i>Astrocaryum jauari</i> Mart.....                                      | 31        |
| 3.2.4    | <i>Attalea maripa</i> (Aubl.) Mart. ....                                 | 32        |
| 3.2.5    | <i>Attalea phalerata</i> Mart. ex Spreng. ....                           | 33        |
| 3.2.6    | <i>Attalea speciosa</i> Mart. ex Spreng.....                             | 34        |
| 3.2.7    | <i>Attalea tesmannii</i> Burret.....                                     | 36        |
| 3.2.8    | <i>Astrocaryum ulei</i> Burret. ....                                     | 37        |
| 3.2.9    | <i>Euterpe precatoria</i> Mart.....                                      | 38        |
| 3.2.10   | <i>Mauritiella armata</i> (Kunth) Burret. ....                           | 39        |
| 3.2.11   | <i>Mauritia flexuosa</i> L. f.....                                       | 40        |
| 3.2.12   | <i>Oenocarpus bacaba</i> Mart. ....                                      | 41        |
| 3.2.13   | <i>Oenocarpus bataua</i> Mart.....                                       | 42        |
| 3.2.14   | <i>Socratea exorrhiza</i> (Mart.) H.Wendl. ....                          | 44        |
| 3.3      | FITOFISIONOMIA FLORESTAL .....                                           | 45        |
| 3.4      | A AEROFOTOGRAMETRIA E AS AERONAVES REMOTAMENTE<br>PILOTADAS (RPAS) ..... | 46        |
| 3.5      | REDES NEURAIIS ARTIFICIAIS.....                                          | 48        |
| 3.6      | REDES NEURAIIS CONVOLUCIONAIS .....                                      | 49        |
| 3.7      | YOLOV10X .....                                                           | 50        |



CAPÍTULO I: DETECÇÃO AUTOMÁTICA DE PALMEIRAS A PARTIR DE IMAGENS RGB  
OBTIDAS POR AERONAVES REMOTAMENTE PILOTADAS NA AMAZÔNIA E  
YOLOV10X.....53

|          |                                                                                 |           |
|----------|---------------------------------------------------------------------------------|-----------|
| <b>1</b> | <b>INTRODUÇÃO .....</b>                                                         | <b>55</b> |
| <b>2</b> | <b>MATERIAL E MÉTODOS.....</b>                                                  | <b>58</b> |
| 2.1      | LOCALIZAÇÃO E CARACTERIZAÇÃO FÍSICA DA ÁREA DE ESTUDO .....                     | 58        |
| 2.2      | COLETA DE DADOS DE CAMPO.....                                                   | 60        |
| 2.3      | PREPARAÇÃO DO BANCO DE DADOS.....                                               | 61        |
| 2.3.1    | Pré-processamento das imagens e demarcação das copas individuais de palmeiras . | 61        |
| 2.3.2    | Demarcação das copas individuais.....                                           | 64        |
| 2.4      | TREINAMENTO DO MODELO .....                                                     | 65        |
| 2.5      | MÉTRICAS E MÉTODOS DE AVALIAÇÃO .....                                           | 66        |
| 2.5.1    | IoU ( <i>Intersection over Union</i> ).....                                     | 66        |
| 2.5.2    | Precisão ( <i>Precision</i> ) .....                                             | 67        |
| 2.5.3    | Sensibilidade ( <i>Recall</i> ).....                                            | 67        |
| 2.5.4    | <i>F1-Score</i> .....                                                           | 67        |
| 2.5.5    | mAP ( <i>Mean Average Precision</i> ) .....                                     | 68        |
| 2.5.6    | Validação Cruzada <i>k-Fold</i> .....                                           | 68        |
| 2.5.7    | Pontuação de Confiança ( <i>Confidence Score</i> ) e Incerteza.....             | 68        |
| <b>3</b> | <b>RESULTADOS .....</b>                                                         | <b>70</b> |
| <b>4</b> | <b>DISCUSSÃO .....</b>                                                          | <b>75</b> |
| 4.1      | TREINO E VALIDAÇÃO .....                                                        | 75        |
| 4.2      | TESTE .....                                                                     | 77        |
| 4.3      | MATRIZ DE CONFUSÃO.....                                                         | 77        |
| 4.4      | LIMITAÇÕES E TRABALHOS FUTUROS .....                                            | 81        |
| <b>5</b> | <b>CONCLUSÃO .....</b>                                                          | <b>83</b> |

CAPÍTULO II: IMPACTO DAS VARIAÇÕES SAZONAIS NA DETECÇÃO DE PALMEIRAS  
NA AMAZÔNIA COM YOLOV10X E IMAGENS RGB OBTIDAS POR  
DRONES.....84

|          |                                                             |           |
|----------|-------------------------------------------------------------|-----------|
| <b>1</b> | <b>INTRODUÇÃO .....</b>                                     | <b>86</b> |
| <b>2</b> | <b>MATERIAIS E MÉTODOS.....</b>                             | <b>88</b> |
| 2.1      | LOCALIZAÇÃO E CARACTERIZAÇÃO FÍSICA DA ÁREA DE ESTUDO ..... | 88        |
| 2.2      | DADOS .....                                                 | 89        |
| 2.3      | PRÉ-PROCESSAMENTO E TREINAMENTO DOS DADOS.....              | 90        |

|                                                                                                                            |                                                                                   |     |
|----------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------|-----|
| 2.4                                                                                                                        | MÉTRICAS.....                                                                     | 90  |
| 2.5                                                                                                                        | COMPARAÇÃO ENTRE PERÍODOS SAZONAIS VIA VALIDAÇÃO CRUZADA E <i>BOOTSTRAP</i> ..... | 91  |
| 3                                                                                                                          | <b>RESULTADOS</b> .....                                                           | 93  |
| 4                                                                                                                          | <b>DISCUSSÃO</b> .....                                                            | 99  |
| 5                                                                                                                          | <b>CONCLUSÃO</b> .....                                                            | 105 |
| CAPÍTULO III: DISTRIBUIÇÃO DA DENSIDADE E PROBABILIDADE DE OCORRÊNCIA DE 14 ESPÉCIES DE PALMEIRAS NA REGIÃO AMAZÔNICA..... |                                                                                   | 106 |
| 1                                                                                                                          | <b>INTRODUÇÃO</b> .....                                                           | 108 |
| 2                                                                                                                          | <b>MATERIAIS E MÉTODOS</b> .....                                                  | 110 |
| 2.1                                                                                                                        | VISÃO GERAL DA METODOLOGIA APLICADA .....                                         | 110 |
| 2.2                                                                                                                        | ÁREA DE ESTUDO .....                                                              | 111 |
| 2.3                                                                                                                        | DADOS .....                                                                       | 112 |
| 2.3.1                                                                                                                      | Densidade das Palmeiras .....                                                     | 112 |
| 2.3.2                                                                                                                      | Vegetação, Pedologia e Relevô .....                                               | 113 |
| 2.3.3                                                                                                                      | Precipitação .....                                                                | 115 |
| 2.3.4                                                                                                                      | Temperatura.....                                                                  | 115 |
| 2.3.5                                                                                                                      | Hidrografia e Índice Topográfico de Umidade .....                                 | 116 |
| 2.4                                                                                                                        | MODELAGEM DA DENSIDADE COM <i>RANDOM FOREST</i> .....                             | 118 |
| 2.4.1                                                                                                                      | Mapas preditivos .....                                                            | 119 |
| 3                                                                                                                          | <b>RESULTADOS</b> .....                                                           | 121 |
| 3.1                                                                                                                        | ANÁLISE DESCRITIVA .....                                                          | 121 |
| 3.2                                                                                                                        | MODELAGEM DA DENSIDADE EM LARGA ESCALA .....                                      | 122 |
| 3.2.1                                                                                                                      | <i>Random Forest</i> .....                                                        | 122 |
| 3.2.2                                                                                                                      | Mapas preditivos .....                                                            | 126 |
| 4                                                                                                                          | <b>DISCUSSÃO</b> .....                                                            | 129 |
| 5                                                                                                                          | <b>CONCLUSÃO</b> .....                                                            | 132 |
| <b>REFERÊNCIAS BIBLIOGRÁFICAS</b> .....                                                                                    |                                                                                   | 133 |
| <b>ANEXO 1</b> .....                                                                                                       |                                                                                   | 149 |
| <b>ANEXO 2</b> .....                                                                                                       |                                                                                   | 150 |
| <b>ANEXO 3</b> .....                                                                                                       |                                                                                   | 151 |
| <b>ANEXO 4</b> .....                                                                                                       |                                                                                   | 152 |

**ANEXO 5.....153**

**ANEXO 6.....154**

**ANEXO 7.....155**

**ANEXO 8.....156**

**ANEXO 9.....157**

**ANEXO 10.....158**

**ANEXO 11.....159**

**ANEXO 12.....160**

**ANEXO 13.....161**

## AGRADECIMENTOS

A conclusão deste doutorado foi possível graças ao apoio, à orientação e à colaboração de diversas pessoas e instituições, às quais expresso minha profunda gratidão.

À minha orientadora, Ana Paula Dalla Corte pela confiança depositada, pela orientação científica atenta e precisa e pelo constante incentivo ao longo de toda a minha trajetória neste doutorado.

Ao meu coorientador, Evandro Orfanó Figueiredo, pelo apoio técnico, pelas valiosas contribuições metodológicas, pela confiança no meu trabalho e pela generosidade em compartilhar seu conhecimento. Em seu nome, estendo meus agradecimentos à Empresa Brasileira de Pesquisa Agropecuária (Embrapa) pela oportunidade de colaboração, à toda a equipe do projeto Netflora pelo trabalho conjunto.

Ao meu coorientador Eben North Broadbent, por me acolher em sua equipe e ampliar minha formação com uma visão internacional e interdisciplinar. Estendo meu agradecimento ao professor Carlos Alberto Silva do SilvaLab pela receptividade, pelo apoio durante o período de intercâmbio e pelas contribuições valiosas à minha trajetória acadêmica.

À Universidade Federal do Paraná (UFPR), pela infraestrutura acadêmica e científica disponibilizada ao longo do doutorado, pelo ambiente formativo de excelência e pelo compromisso com a pesquisa pública de qualidade. Agradeço aos professores, técnicos e colegas do Programa de Pós-Graduação em Engenharia Florestal, que contribuíram direta ou indiretamente para minha formação acadêmica e pessoal.

Agradeço à CAPES e ao CNPq pelo suporte financeiro, essencial para a realização das atividades de campo, análises e estágio de pesquisa no exterior, apoio viabilizado com recursos públicos, oriundos da contribuição da população brasileira, a quem também dedico minha gratidão. Como forma de retribuição, devolvo à sociedade o conhecimento e os resultados gerados por esta pesquisa, com o compromisso de que possam contribuir para o desenvolvimento científico, tecnológico, ambiental e social do País. Agradeço também ao Fundo JBS pela Amazônia pela bolsa concedida.

À minha família, por todo amor, paciência e apoio incondicional em cada etapa desta jornada. Aos amigos, pelos momentos de escuta, companheirismo e incentivo, que foram fundamentais para manter o equilíbrio e a motivação nos momentos mais desafiadores.

A todas e todos que, direta ou indiretamente, contribuíram para a realização deste trabalho, meu muito obrigado.

## 1 CONTEXTUALIZAÇÃO

No final do século XIX, a crescente demanda de látex pela então recente indústria automobilística, atraiu diversos imigrantes, principalmente da região nordeste, para o sudoeste da Amazônia. Fato este, que levou a intensa modificação da região, até então pouco explorada.

No início do século seguinte houve o grande colapso da borracha, principalmente devido à concorrência com a Malásia, ocasionando o êxodo dos seringueiros, dando início ao processo de urbanização de cidades como Rio Branco, no Acre. Como alternativa para a borracha, iniciou-se a extração predatória de madeira e da pecuária extensiva em grande escala, levando a substituição dos antigos seringais por áreas de pastagem, modificando assim gradativamente o tipo de uso do solo. Essa intensa transformação da paisagem exige da sociedade uma análise mais profunda do aproveitamento socioeconômico dos recursos. Tendo como principal desafio a garantia da sustentabilidade dos sistemas de produção, respeitando a diversidade biológica e os modos de vida das populações locais.

As palmeiras (Arecaceae), presentes em todo o Bioma Amazônia, destacam-se pelo importante papel no fortalecimento das economias locais amazônicas, além da contribuição para a economia nacional. Em 2023 apenas o açaí (*Euterpe precatoria* Mart.) contribuiu 853,1 milhões de reais para o PIB nacional (IBGE, 2024). Além do açaí, outras espécies de se destacam por oferecer uma gama de produtos florestais não madeireiros como frutos, palmitos, combustível, óleos, tecidos, fibras e materiais para construção. Esses produtos, em sua maioria, são ainda pouco explorados principalmente devido à escassez de estudos e investimentos em infraestrutura nos sistemas de produção relacionados as palmeiras. Por conta disso, é importante avançar no desenvolvimento de pesquisas que ofereçam alternativas robustas para o monitoramento e os manejos sustentável dos ecossistemas naturais onde as palmeiras ocorrem. Estudos envolvendo tecnologias de sensoriamento remoto, análise espectral e modelagem ecossistêmica são fundamentais para compreender melhor as dinâmicas populacionais das palmeiras e suas interações com outros componentes bióticos e abióticos do ecossistema, uma vez que garantem celeridade no processo de mapeamento e monitoramento, reduzindo significativamente os custos operacionais (Casapia et al. 2025). Ademais, políticas públicas que fomentem investimentos em infraestrutura de processamento e comercialização de produtos não madeireiros são estratégicas para otimizar a exploração sustentável desses recursos. Tal abordagem possibilita não apenas o fortalecimento

econômico das comunidades locais, mas também contribui para a conservação da biodiversidade e a resiliência dos ecossistemas amazônicos frente às mudanças ambientais.

Os métodos tradicionais de monitoramento da vegetação, são baseados em inventários florestais de campo que apresentam custos elevados e esforços envolvidos. As dificuldades aumentam tratando-se da complexidade do Bioma Amazônia. Conhecer a distribuição espacial e a densidade das palmeiras é primordial para o planejamento da exploração e o manejo comercial, como também avançar no desenvolvimento de ferramentas que facilitam e automatizam esse processo torna-se fundamental (Nevalainen et al., 2017).

Técnicas de visão computacional, aplicadas às análises das imagens de Sensoriamento Remoto, especialmente de aprendizado profundo baseadas em Redes Neurais Convolucionais (CNNs), têm se mostrado adequadas para a identificação de palmeiras em áreas de florestas (Dos Santos et al., 2017, Ferreira et al., 2020, Karasinski, 2021; Jintasuttisak et al., 2022). As CNNs se destacam quando comparadas a outros métodos de classificação, uma vez que, no processo de aprendizagem, conseguem armazenar características espaciais de uma imagem além de depender de um nível mínimo de pré-processamento, sendo amplamente utilizadas no reconhecimento de padrões em imagens.

Recentemente, uma variedade de métodos de detecção de objetos de ponta a ponta foi aplicada ao campo de detecção de copas das árvores, como Faster R-CNN (Zheng et al., 2019), RetinaNet (Selvaraj et al., 2020, Culman et al., 2020), YOLOv2, YOLOv3, YOLOv4 e YOLOv5 (Puttamans et al., 2018; Itakura e Hosoi, 2020, Jintasuttisak et al., 2022) e R-CNN Mask (Braga et al., 2020). Em geral, o método baseado na detecção de objetos é mais rápido e robusto quando comparado a outros métodos de detecção de copas de árvores, principalmente em florestas com diversidade de espécies (Zheng et al., 2021). Um modelo que avançou muito na categoria de detecção de objetos foi o YOLOv1, abreviação de *You Only Look Once* (Redmon et al., 2016). Enquanto muitos sistemas de detecção de objetos precisam passar pela imagem mais de uma vez para detectar todos os objetos na imagem, YOLO coloca a detecção de objetos como um problema de regressão por *bounding boxes* espacialmente separadas e suas respectivas probabilidades de classe associadas. Uma vez que uma única rede neural prevê probabilidades de caixa delimitadora e classe diretamente em imagens completas em um único estágio, ou seja, detecta todos os objetos analisando a imagem apenas uma vez. Seu design permite o treinamento de ponta a ponta em velocidade em tempo real sem perder a precisão da detecção (Redmon et al., 2016).



Estudar a vegetação natural, muitas vezes, pode ser um desafio devido sua complexidade, principalmente ao trabalhar com reconhecimento de padrões, pois a floresta passa por diferentes transformações ao longo do ano devido aos eventos vegetativos e reprodutivos das espécies, bem como as relações com fatores ambientais e bióticos (Maciel-Silva, 2011; Missagia et al. 2014). Diante disso, compreender a fenologia dos ecossistemas florestais e a biodiversidade regional torna-se uma ferramenta importante a ser considerada durante a execução de estudos que envolvam reconhecimento de padrões a partir de imagens de sensoriamento remoto.

Dessa forma, esta pesquisa busca responder as seguintes questões:

O algoritmo de detecção e classificação YOLOv10 é uma ferramenta eficaz para o mapeamento de 14 espécies de palmeiras economicamente importantes em Florestas Tropicais Amazônicas?

Os diferentes estágios fenológicos da floresta afetam na precisão da detecção e classificação pelo algoritmo das espécies de palmeiras testadas neste estudo?

É possível representar espacialmente a densidade das espécies das palmeiras estudadas em larga escala?

## 1.1 ESTRUTURA DA TESE

Para responder a estas questões, foram coletados dados de inventário de palmeiras e imagens RGB a partir RPAs nos estados do Acre (regionais Juruá, Tarauacá/Envira, Purus, Baixo Acre e Alto Acre), Rondônia (Madeira-Guaporé e Vale do Jamari), Amazonas (Sul Amazonense) e Roraima (Norte e Sul), sendo esta pesquisa subdivida em três capítulos.

No Capítulo 1, foi avaliado o desempenho do algoritmo YOLOv10 para a detecção de 14 espécies de palmeiras a partir de imagens obtidas por RPA. Primeiramente, foi criada uma ampla base de dados de imagens (~27 mil) (*dataset*) obtidas em 47 diferentes locais (sítios) e em diferentes estações do ano. As imagens foram rotuladas manualmente com base nas classes de espécies de palmeiras e, em seguida, utilizadas no processo de treinamento e avaliação do modelo. Os dados foram agrupados em 7 regiões distintas (Alto Acre, Baixo Acre, Juruá, Rondônia, Roraima, Sul Amazonense e Tarauacá-Envira), além da combinação de todas as regiões agrupadas. A validação foi realizada por meio de validação cruzada com três partições ( $k=3$ ), utilizando métricas derivadas da matriz de confusão, como precisão, recall, F1-score para estimar o desempenho preditivo e a capacidade de generalização do modelo entre as diferentes regiões.

No Capítulo 2, uma parcela do *dataset* foi separada entre os períodos chuvoso e seco na região do Vale do Acre, no estado do Acre, com o objetivo de avaliar o efeito das fenofases da floresta sobre o desempenho do modelo de detecção. A validação foi realizada por meio de validação cruzada com cinco partições ( $k=5$ ), e as métricas de desempenho (precisão, recall e F1-score) foram comparadas entre os dois períodos. Para testar a significância das diferenças observadas, aplicou-se um método de *bootstrap* pareado (reamostragem com 10.000 repetições), estimando intervalos de confiança de 95%. Essa abordagem permitiu verificar se as variações no desempenho entre os períodos chuvoso e seco eram estatisticamente significativas.

O Capítulo 3 concentrou-se na geração de mapas de densidade e distribuição das espécies de palmeiras na região, com ênfase para o estado do Acre, o qual apresentou melhor distribuição dos dados de campo. Para isso, foi utilizado o melhor modelo treinado no Capítulo 1, o qual permitiu realizar previsões em diferentes regiões estudadas. As espécies foram organizadas com base em suas principais cadeias produtivas de interesse, como alimentícios, biocombustíveis e cosméticos. Em seguida, as densidades foram estimadas a partir de modelos *Random Forest* treinados com variáveis ambientais (clima, solo topografia, localização geográfica), aplicando-se uma validação baseada em reamostragem com *bootstrapping*. Essa abordagem permitiu quantificar a incerteza das previsões e gerar mapas robustos que evidenciam padrões espaciais distintos de ocorrência, subsidiando a identificação de áreas prioritárias para o planejamento territorial e o fomento à bioeconomia.

## 2 OBJETIVOS

### 2.1 OBJETIVO GERAL

Investigar o potencial da integração entre técnicas de *Deep Learning* e *Machine Learning* aplicadas imagens RGB obtidas por aeronaves remotamente pilotadas (RPA), para detectar, quantificar e mapear espacialmente a ocorrência de 14 espécies de palmeiras na Amazônia.

### 2.2 OBJETIVOS ESPECÍFICOS

- a) Treinar e validar o modelo YOLOv10x para a detecção e discriminação de 14 espécies de palmeiras em imagens RGB de alta resolução obtidas por RPA em diferentes regiões da Amazônia.
- b) Avaliar o efeito do período da coleta das imagens na detecção e classificação das espécies de palmeiras.
- c) Avaliar o potencial da extração de variáveis qualitativas e quantitativas para as espécies de palmeiras.
- d) Gerar mapas de distribuição e densidade por espécie, como subsídio à identificação de zonas prioritárias para o fortalecimento de cadeias produtivas da bioeconomia amazônica.

### 3 REVISÃO DE LITERATURA

#### 3.1 PRODUTOS FLORESTAIS NÃO MADEIREIROS

Os produtos florestais não madeireiros (PFNMs) são todos aqueles bens de origem biológica provenientes das florestas que não envolvem a extração direta da madeira para fins industriais. Esses produtos incluem uma ampla variedade de recursos como frutos, sementes, folhas, resinas, plantas medicinais, fibras, cogumelos, mel, óleos essenciais, fauna silvestre e materiais para artesanato e indústria. Os PFNMs podem ser coletados de florestas naturais, sistemas agroflorestais ou plantações, e estão presentes tanto em ecossistemas tropicais quanto temperados. Essa categoria abrange recursos com valor comercial e de subsistência, sendo fundamentais para populações tradicionais, agricultores familiares, povos indígenas e comunidades rurais (Pedrozo et al., 2011; Nyegren et al., 2006).

A importância dos PFNMs vai além de sua utilidade direta para alimentação, saúde ou uso doméstico. Eles são peças-chave no fortalecimento da bioeconomia, um modelo de desenvolvimento baseado na utilização sustentável da biodiversidade para geração de valor, emprego e inovação. Em um mundo em transição energética e busca por soluções de baixo carbono, os PFNMs representam alternativas viáveis para substituição de insumos industriais por bioprodutos, como cosméticos naturais, fitoterápicos, biocombustíveis e alimentos funcionais. Além disso, muitas dessas espécies desempenham papéis essenciais na manutenção dos serviços ecossistêmicos, como ciclagem de nutrientes, polinização e regulação hídrica, contribuindo com a resiliência ambiental necessária frente às mudanças climáticas (Rego, 1999; Lescure, 2000; Coslovsky, 2021).

Globalmente, os PFNMs têm desempenhado papel estratégico na geração de renda e na valorização dos modos de vida locais. Na Amazônia, por exemplo, o açaí representa quase metade do valor da produção de PFNMs alimentícios, demonstrando seu potencial econômico (IBGE, 2023). Entre 2017 e 2019, a Amazônia registrou a exportação de 64 produtos provenientes do extrativismo florestal não madeireiro, sistemas agroflorestais, pesca, piscicultura e hortifruticultura tropical. Esses produtos geraram uma receita anual em torno de US\$ 298 milhões. No entanto, esse valor ainda representa uma fração modesta (0,17%) do total movimentado globalmente por produtos da mesma categoria (Coslovsky, 2021).

Apesar de seu grande potencial, a exploração dos PFNMs ainda enfrenta diversos desafios, como a coleta insustentável, a falta de estrutura para comercialização, o desconhecimento do valor econômico real dos produtos de subsistência e a baixa capacitação técnica das comunidades envolvidas. Além disso, o impacto das mudanças climáticas,

incêndios florestais e degradação ambiental vêm afetando negativamente a disponibilidade e produtividade desses recursos (Vinceti et al., 2022). Assim, políticas públicas que incentivem o manejo sustentável, o fortalecimento das cadeias de valor e a inclusão produtiva das populações locais são essenciais para que os PFNMs se consolidem como uma base estratégica da bioeconomia e da transição ecológica nos territórios florestais.

No Brasil, entre os produtos extrativos não madeireiros, o açaí se destaca como o principal em valor de produção, alcançando R\$ 853,1 milhões em 2023, seguido pela erva-mate, com R\$ 589,6 milhões. No grupo dos produtos alimentícios, os itens que mais contribuíram para o valor total da produção foram o açaí (46,0%), a erva-mate (31,8%), a castanha-do-pará ou castanha-do-brasil (9,3%), o pequi (3,5%) e o pinhão (3,3%). Além desses, destacam-se produtos com usos industriais e múltiplas finalidades, como a carnaúba, com R\$ 209,4 milhões, utilizada na fabricação de ceras e cosméticos, e o babaçu, com R\$ 68,1 milhões, importante para a produção de óleo e outros derivados (IBGE, 2023). Esses números evidenciam a diversidade e relevância dos PFNMs na economia brasileira, reforçando seu papel como fontes sustentáveis de renda, geração de emprego e agregação de valor na transição para uma bioeconomia baseada no uso racional da biodiversidade nativa.

### 3.2 PALMEIRAS

As palmeiras (família Arecaceae) compõem um dos grupos botânicos mais diversos e emblemáticos das florestas tropicais, com cerca de 181 gêneros e aproximadamente 2.500 espécies distribuídas em diferentes ecossistemas (Henderson et al. 1995; Lorenzi et al., 2004; Cámara-Leret et al., 2017). Seu papel ecológico é notável, uma vez que muitas espécies são fontes importantes de alimento para a fauna silvestre, sustentando cadeias tróficas por meio de frutos e flores (Onstein et al., 2017). Na Amazônia, palmeiras são particularmente dominantes: cerca de 60% das plantas mais comuns pertencem a esse grupo, com mais de 160 espécies distribuídas em pelo menos 35 gêneros (Ter Steege et al., 2013; Alvez-Valles et al., 2018). Essa riqueza de espécies, associada à diversidade de formas de crescimento e potencial de uso, coloca as palmeiras entre os recursos florestais não madeireiros (PFNMs) mais relevantes da região (Balslev et al., 2015; Moraes, 2020).

As palmeiras fornecem uma ampla gama de produtos usados pelas populações tradicionais e pela indústria, incluindo frutos, sementes, palmitos, óleos, fibras e materiais para construção ou cosméticos (Balslev, 2011; Shackleton et al., 2018). Muitas espécies amazônicas, como *Euterpe precatoria* e *Euterpe oleracea* (açaí), *Bactris gasipaes* (pupunha),

*Mauritia flexuosa* (buriti) e *Oenocarpus bataua* (pataua), têm alto valor nutricional, sendo ricas em antioxidantes e ácidos graxos insaturados (Darnet et al., 2011; dos Santos et al., 2015). Além disso, a extração dos frutos dessas espécies não implica a morte da planta, como ocorre com o palmito, tornando sua exploração menos impactante. Com a crescente demanda internacional por alimentos funcionais e óleos vegetais sustentáveis, essas palmeiras ganham importância como alternativas comerciais viáveis e inclusivas no contexto da bioeconomia (Smith, 2014; Moraes, 2014).

Apesar do potencial, a trajetória de uso e desenvolvimento de espécies nativas de palmeiras tem sido marcada por avanços e fracassos. O sucesso comercial do açaí contrasta com os desafios enfrentados por espécies como a macaúba (*Acrocomia aculeata*) e o babaçu (*Attalea speciosa*), cujos programas de pesquisa e desenvolvimento (P&D) sofreram com descontinuidade, falta de compreensão das cadeias produtivas e ausência de planejamento de longo prazo (Clement et al., 2004; Hartley, 1988). A viabilidade econômica dessas espécies é frequentemente comprometida por fatores como sazonalidade, maturação irregular, custos logísticos e baixa agregação de valor local.

Por fim, o sucesso na comercialização sustentável de produtos derivados de palmeiras depende de múltiplos fatores interligados: ecológicos, socioeconômicos, políticos e institucionais (Shackleton, 2015; Hernández-Barrios et al., 2015). O aumento da demanda e do valor de mercado pode trazer benefícios financeiros, mas também riscos de sobre-exploração, como já observado em outras cadeias de PFNMs que seguiram ciclos de “boom and bust” (Homma, 1992; Belcher & Schreckenberg, 2007). Estratégias integradas de manejo e comercialização, aliadas ao uso de tecnologias de monitoramento, à organização comunitária e ao apoio de políticas públicas consistentes são fundamentais para que o uso das palmeiras contribua, de fato, para a conservação da biodiversidade e o desenvolvimento sustentável de regiões tropicais.

As palmeiras apresentam uma notável diversidade morfológica, com formas de crescimento que variam desde arbustos de pequeno porte até espécies que atingem alturas elevadas, comparáveis a grandes árvores. Essa variabilidade estrutural influencia diretamente o potencial de detecção por meio de tecnologias de sensoriamento remoto. De acordo com Kissling et al. (2019), cerca de 40% das palmeiras possuem hastes com diâmetro igual ou superior a 10 cm a 1,30 metros do solo, o que favorece sua identificação em levantamentos aéreos. A utilização de drones, equipados com câmeras RGB, multiespectrais ou LiDAR, permite a fotointerpretação e o mapeamento dessas espécies em alta resolução, contribuindo



significativamente para estudos de ecologia, manejo florestal e avaliação de recursos não madeireiros. A seguir, são apresentadas algumas das principais espécies de palmeiras amazônicas com potencial de detecção aérea, destacando-se por sua relevância ecológica, importância econômica, características morfológicas e presença marcante em diferentes ambientes da região.

### 3.2.1 *Astrocaryum aculeatum* G. Mey.

*Astrocaryum aculeatum* G. Mey. (FIGURA 1) ocorre naturalmente nos estados do Acre, Amazonas, Pará e Rondônia, sendo uma espécie solitária de terra firme, com estipe ereto, alcançando de 8 a 20 m de altura e 12 a 40 cm de diâmetro (Henderson et al., 1995). Popularmente conhecido como tucumã, possui estipe recoberto por espinhos de até 15 cm nos entrenós. As folhas possuem de 5 a 15 pinas com bainha, pecíolo e raque também coberta de espinhos. Seus frutos são globosos com mesocarpo carnoso e comestível, sendo amplamente utilizado para alimentação.

Na região de Manaus, os frutos do tucumã estão inseridos na culinária e são comercializados in natura ou beneficiado localmente pelos próprios comerciantes, sendo abundante em feiras livres e com alto potencial para a industrialização (COSTA, 2005). As fibras das folhas e o estipe são usados para confecção de artesanatos e utensílios como redes, cestos, cordas e arcos.

FIGURA 1 - *Astrocaryum aculeatum* (TUCUMÃ) OBSERVADO A PARTIR DO SOLO (ESQUERDA, FOTO: RUBEM D. LAYME) E POR IMAGEM AÉREA (DIREITA).



FONTE: o autor (2025).

### 3.2.2 *Attalea butyracea* (Mutis ex L.f.) Wess.Boer

*Attalea butyracea* (Mutis ex L.f.) Wess. Boer (FIGURA 2), popularmente conhecida como jací, é uma das palmeiras neotropicais mais abundantes (Henderson et al., 1995), com uma haste grossa de até 50 cm de diâmetro e 15-20 m de altura. Possui uma grande coroa de 15 a 40 folhas pinadas que alcançam entre 6 a 7 metros de comprimento e 80 cm de largura. Os folíolos são regularmente dispostos na raque de forma linear e no mesmo plano. Possuem grandes inflorescências fechadas em uma espessura bráctea pedunculares lenhosas. As infrutescências são grandes e pendentes, e carregam numerosos frutos densamente dispostos, elíptico, com 4,5 a 8,5 cm de comprimento e 2,5 a 4,5 cm de diâmetro, de cor amarelada, laranja e marrom, com um endocarpo lenhoso espesso e com 2 a 3 sementes estreitamente elípticas, de 3 a 5 cm de comprimento e 0,5 a 1,2 mm de espessura (Henderson, 1995; Lorenzi et al., 2000; Ferreira et al., 2020). Suas folhas são amplamente utilizadas em comunidades amazônicas para a construção de telhados e artesanatos (Bernal et al., 2010),

seus frutos são consumidos com farinha de mandioca em culinária regional, além de possuir um elevado potencial para a produção de biodiesel (Mendonça e Ferreira, 2010).

FIGURA 2 - *Attalea butyracea* (JACI) OBSERVADO A PARTIR DO SOLO (ESQUERDA, FOTO: ARTURO C. MENDOZA) E POR IMAGEM AÉREA (DIREITA).



FONTE: o autor (2025).

### 3.2.3 *Astrocaryum jauari* Mart.

O jauari (*Astrocaryum jauari* Mart.) (FIGURA 3) é uma imponente palmeira cespitosa que alcança até 20 metros de altura e 30 cm de diâmetro, com entrenós armados de espinhos achatados e negros de até 15 cm. Nativa de áreas alagáveis da Amazônia, essa palmeira se distribui ao longo de margens de rios, lagoas e igarapés, encontrando-se nos estados do Acre, Amapá, Amazonas, Pará, Rondônia e Roraima. Suas folhas pinadas, que medem até 3,6 metros de comprimento, são dispostas em grupos irregulares e protegidas por espinhos que variam entre tons de negro e cinza, conferindo à planta um aspecto robusto e resistente (Henderson et al., 1995). O jauari tem múltiplos usos para as comunidades locais: suas folhas são uma valiosa fonte de fibras, utilizadas na confecção de redes e tecidos, enquanto o palmito, grande e saboroso, é apreciado na culinária. Seus frutos, globosos e



variando entre amarelo e alaranjado, servem de isca para pescaria e possuem um endocarpo negro e duro, utilizado para fabricar biojóias como colares e pulseiras. As inflorescências eretas e infrutescências ricas em ráquias com flores masculinas e femininas conferem à palmeira uma aparência singular, enquanto seus frutos elipsoides de 2,5 a 5 cm de comprimento tornam-se essenciais para a fauna local, fornecendo alimento e contribuindo para a biodiversidade das áreas ribeirinhas (Piedade et al. 2014).

FIGURA 3 - *Astrocaryum jauari* (JAUARI) OBSERVADO A PARTIR DO SOLO (ESQUERDA, FOTO: PEDRO ALONSO) E POR IMAGEM AÉREA (DIREITA).



FONTE: o autor (2025).

#### 3.2.4 *Attalea maripa* (Aubl.) Mart.

O inajá (*Attalea maripa* (Aubl.) Mart.) (FIGURA 4) é uma palmeira oleaginosa amplamente presente na região amazônica. É uma palmeira monocaule que pode atingir de 3,5 até 20 metros de altura, essa espécie é resistente a pragas, seca, solos compactados e degradados, e é capaz de colonizar áreas impactadas (Miranda et al., 2001). Seus frutos são ricos em óleo e produzidos em abundância, sendo consumidos tanto por humanos quanto por animais, como antas, araras e macacos, que ajudam na dispersão das sementes (Shanley et al.,



2010). A polpa é amarela e levemente adocicada, consumida fresca ou cozida. Além de fornecer óleo com potencial para biodiesel, o inajá é uma fonte para alimentação e cosméticos (Miranda et al., 2001) e o óleo obtido da amêndoa do fruto de inajá (cerca de 60%) apresenta em sua composição, ácidos graxos essenciais que se destacam por sua relevância de caráter nutricional (Miranda et al. 2001; Bezerra, 2011. Embora manejada por comunidades ribeirinhas e indígenas, a exploração é ainda limitada pelo baixo conhecimento científico e pela falta de estratégias de conservação frente ao desmatamento, o que representa um risco à preservação dessa valiosa espécie amazônica.

FIGURA 4 - *Attalea maripa* (INAJÁ) OBSERVADO A PARTIR DO SOLO (ESQUERDA, FOTO: RICH HOYER) E POR IMAGEM AÉREA (DIREITA).



FONTE: o autor (2025).

### 3.2.5 *Attalea phalerata* Mart. ex Spreng.

De nome popular urucuri, uricuri, *Attalea phalerata* Mart. ex Spreng. (FIGURA 5) possui caule solitário, de 5 a 10 metros de altura e 60 a 75 cm de diâmetro, revestido até pouco abaixo da metade do caule com as bases foliares persistentes já caídas. Suas folhas são pinadas dispostas em vários planos, o que garante um aspecto plumoso. O urucuri é também



uma espécie considerada como de elevado potencial econômico, dada a diversidade de usos populares a ela associados, incluindo emprego como fonte alimentar dos frutos, recursos forrageiros, material para construções e fonte de biodiesel entre outros (Guarim Neto, 1992; Miranda et al., 2001).

FIGURA 5 - *Attalea phalerata* (URUCURI) OBSERVADO A PARTIR DO SOLO (ESQUERDA, FOTO: ALFREDO GUTIERREZ DIPAZ) E POR IMAGEM AÉREA (DIREITA).



FONTE: o autor (2025).

### 3.2.6 *Attalea speciosa* Mart. ex Spreng.

O babaçu (*Attalea speciosa* Mart. ex Spreng.) (FIGURA 6) é uma palmeira de porte elevado, com estipe solitário que pode alcançar entre 6 e 30 metros de altura e diâmetro de 30 a 70 cm, com superfície lisa. Suas folhas são longas e dispostas em espiral ao redor do tronco, com até 12,50 m de comprimento, curvando-se principalmente na ponta. Cada lado da raque contém entre 150 e 280 pinas, que se dispõem de forma regular e única ao longo do caule. A inflorescência é interfoliar e andrógina, com flores masculinas e femininas ocorrendo tanto na mesma planta quanto em plantas separadas. Os frutos, de formato ovóide, medem de 7,5 a 13 cm de comprimento e possuem epicarpo marrom e endocarpo resistente, com estrias

longitudinais e fibras escuras no interior (Henderson, 1995; Soares, 2024). A espécie é amplamente distribuída e adaptada às condições do Brasil, sendo especialmente abundante nas regiões de clima tropical. O babaçu é uma palmeira que oferece uma vasta gama de produtos aproveitáveis, sendo o fruto a parte mais valorizada economicamente, com capacidade para originar mais de 64 subprodutos (SNIF, 2024). Como alimento, o fruto gera uma manteiga vegetal de sabor agradável e alto valor nutritivo, e as amêndoas podem ser consumidas in natura. Além disso, o fruto do babaçu possui grande relevância econômica, social, cultural e até política nas regiões Norte e Nordeste do Brasil, onde movimentos organizados, como o Movimento Interestadual das Quebradeiras de Coco Babaçu (MIQCB), defendem os interesses das quebradeiras de coco nos estados do Maranhão, Pará, Piauí e Tocantins, promovendo a preservação de práticas tradicionais e o acesso aos recursos naturais da espécie (SNIF, 2024).



FIGURA 6 - *Attalea speciosa* (BABAÇU) OBSERVADO A PARTIR DO SOLO (ESQUERDA, FOTO: LUCAS C. MARINHO) E POR IMAGEM AÉREA (DIREITA).



FONTE: o autor (2025).

### 3.2.7 *Attalea tesmannii* Burret.

Também conhecida por cocão, *Attalea tesmannii* Burret. (FIGURA 7) possui caule solitário de 12 a 24 metros de altura e 25 a 46 cm de diâmetro revestidos pelos remanescentes das folhas que já caíram (Lorenzi et al., 2004). Suas folhas são pinadas dispostas de forma agrupadas e em diferentes planos ao longo da raque, dando um aspecto plumoso. Os frutos são oblongos e medem de 11 a 15 cm de comprimento. Embora suas folhas possam ser ocasionalmente utilizadas para cobertura de casas, o seu principal potencial está nas amêndoas, pois seu interior é comestível e altamente oleaginoso, e além disso, o resíduo da produção de óleos apresenta elevado potencial para a indústria de carvão (Da Silva Sousa et al., 2022).



FIGURA 7 - *Attalea tessmannii* (COCÃO) OBSERVADO A PARTIR DO SOLO (ESQUERDA, FOTO: EVANDRO FERREIRA) E POR IMAGEM AÉREA (DIREITA).



FONTE: o autor (2025).

### 3.2.8 *Astrocaryum ulei* Burret.

Popularmente conhecida como murumuruzeiro ou murumuru, *Astrocaryum ulei* Burret. (FIGURA 8) é uma palmeira que ocorre tanto em terra firme, principalmente em áreas úmidas, quanto em baixios, próximos a rios e lagos, e com alta densidade. Apresenta-se como touceira ou com estipe solitário, suas folhas têm bainha, pecíolo e raque cobertos por espinhos alongados, negros e achatados e suas as pinas apresentam coloração quase branca abaxialmente e estão regularmente arranjadas e dispostas em um mesmo plano. (Do Nascimento et al. 2007). Seus frutos apresentam cor amarelada quando maduro e suas sementes são altamente oleaginosas.

O murumuru possui alto potencial na indústria alimentícia, principalmente para a produção de óleos e margarina, além de possuir elevado papel na indústria de cosméticos para produção de sabonetes e cremes, bem como para a produção de biodiesel (Do Nascimento et

al. 2007). Além disso, usos como multiprodutos foram relatados, como a produção de adubos, fibras, artesanato, palha de cobertura e planta ornamental (Frankie, 1999).

FIGURA 8 - *Astrocaryum ulei* (MURUMURU) OBSERVADO A PARTIR DO SOLO (ESQUERDA, FOTO: VANESSA FLORES) E POR IMAGEM AÉREA (DIREITA).



FONTE: o autor (2025).

### 3.2.9 *Euterpe precatoria* Mart.

*Euterpe precatoria* Mart., (açai-solteiro) (FIGURA 9) ocorre em vários habitats, em terrenos alagados e também em terras não alagadas. Pode ser comum na várzea, mas também ocorre em rampas andinas íngremes a 2000 m de altitude (Kahn, 1993; Henderson, 1995). Possui raízes adventícias continuamente na base do estipe, formando um anel espesso na base (1,5 cm) de cor púrpura, podendo alcançar 80 cm do nível do solo (Bovi e Castro, 1993). As inflorescências *E. precatoria* Mart. têm numerosas flores masculinas (4,5 x 2,7 mm) e femininas (3,2 x 2,6 mm). As flores masculinas abrem e liberam o pólen antes que as flores femininas sejam receptivas e desta forma não ocorre autofecundação, sendo a polinização cruzada geralmente entomófila com predominância de besouros e abelhas como polinizadores potenciais (Küchmeister et al., 1997; Lorenzi et al., 2010). Os frutos são globosos e de cor púrpura-escuro quando maduros, com mesocarpo suculento, existindo uma semente por fruto, com endosperma sólido e homogêneo (Henderson, 1995). A produção de frutos é anual nos



períodos entre março/abril a setembro (Rocha, 2004). Possui forma de copa linear, regularmente espaçada, de padrão estrelado, com raio de copa inferior a 7 metros, sendo facilmente distinguível em imagens aéreas (Ferreira et al., 2020). Além da produção local para a subsistência de famílias locais, a produção do açaí vem cada vez mais conquistando o mercado nacional e de exportação (Tavares, 2020), seu potencial nutricional e energético conquistou principalmente a indústria de alimentos e cosméticos.

FIGURA 9 - *Euterpe precatoria* (AÇAÍ SOLTEIRO) OBSERVADO A PARTIR DO SOLO (ESQUERDA, FOTO: A. ARAUJO) E POR IMAGEM AÉREA (DIREITA).



FONTE: o autor (2025).

### 3.2.10 *Mauritiella armata* (Kunth) Burret.

A buritirana, (*Mauritiella armata* (Kunth) Burret.) (FIGURA 10) também conhecida como buriti-mirim ou caranã, é uma palmeira nativa da região Norte da Amazônia, presente no Brasil e Venezuela. Caracteriza-se por seu estipe cespitoso, que atinge de 3 a 8 metros de altura e 7 a 10 cm de diâmetro, formando densas touceiras de até 50 hastes frequentemente inclinadas, cobertas por espinhos cônicos de cerca de 3 cm (Leitman et al., 2015; Vianna,

2020). Suas folhas, em forma de leque (flabeliformes), são cerosas e de coloração branco-azulada, com pecíolos de 30 a 70 cm e lâminas foliares divididas em 68 a 80 segmentos pêndulos. É uma espécie dioica, com inflorescências interfoliares e ramificadas de segunda ordem; as flores masculinas e femininas ocorrem em plantas separadas, com frutos oblongos de 4 a 5 cm, revestidos por escamas castanho-avermelhadas e polpa carnosa. Seus frutos são consumidos frescos e a polpa utilizada para suco. A buritirana tem ampla aplicação ornamental, sendo cultivada em áreas de sol pleno ou meia-sombra e adaptada a solos bem aerados, preferencialmente arenosos.

FIGURA 10 - *Mauritiella armata* (BURITIRANA) OBSERVADO A PARTIR DO SOLO (ESQUERDA, FOTO: NILS SERVIENTIS) E POR IMAGEM AÉREA (DIREITA).



FONTE: o autor (2025).

### 3.2.11 *Mauritia flexuosa* L. f.

*Mauritia flexuosa* L. f. (FIGURA 11) ocorre em toda a Amazônia, Brasil Central, Bahia, Ceará, Maranhão, Piauí e São Paulo, popularmente conhecida como buriti, é encontrada em áreas de várzea, chamadas de buritizal. O buriti, é uma palmeira exuberante de caule solitário que pode alcançar de 3 a 25 metros de altura. Possui de 10 a 20 folhas



flabeliforme costapalmadas, arranjadas em forma de espiral na copa e persistentes em plantas jovens quando mortas (Lorenzi et al. 2004). Suas folhas são utilizadas para construção de telhados e seus frutos são amplamente utilizados na alimentação, principalmente na forma de suco e doce. Outros produtos de *M. flexuosa*, como folhas jovens e óleo, estão aumentando em valor e potencialmente apresentam desafios de manejo (Sampaio et al., 2008; Abreu et al., 2014)

FIGURA 11 - *Mauritia flexuosa* (BURITI) OBSERVADO A PARTIR DO SOLO (ESQUERDA, FOTO: MAURO A. KARASINSKI) E POR IMAGEM AÉREA (DIREITA).



FONTE: o autor (2025).

### 3.2.12 *Oenocarpus bacaba* Mart.

A bacaba (*Oenocarpus bacaba* Mart.) (FIGURA 12) é uma palmeira de porte arbóreo que apresenta um caule liso, reto e de 7 a 22 metros de altura, com diâmetro entre 12 e 25 cm. De caule único, suas folhas, de comprimento variável entre 2,2 e 5,6 metros, possuem de 75 a 179 pinas agrupadas em várias direções, formando uma copa densa e característica. A planta é monoica, com inflorescências que surgem entre as folhas e são protegidas por duas brácteas decíduas distintas, e suas flores unissexuais se organizam em

tríades ao longo das ráquulas, predominando flores masculinas no ápice (Balick, 1986; Henderson, 1995; Mendonça et al., 2008). Possui elevado potencial econômico, ecológico e alimentar, sendo amplamente adaptável a sistemas agroflorestais. Muito utilizada pelas comunidades locais a bacaba é explorada principalmente pelos frutos comestíveis, usados na produção de uma bebida tradicionalmente conhecida como “vinho de bacaba” e na extração de um óleo comestível de sabor suave, semelhante ao azeite de oliva, além de fornecer palmito de alta qualidade (Mendonça e Araújo, 1999; Queiroz e Bianco, 2009). A versatilidade dessa palmeira torna-a uma espécie promissora para o desenvolvimento sustentável em regiões onde é encontrada.

FIGURA 12 - *Oenocarpus bacaba* (BACABA) OBSERVADO A PARTIR DO SOLO (ESQUERDA, FOTO: RENATA XAVIER) E POR IMAGEM AÉREA (DIREITA).



FONTE: o autor (2025).

### 3.2.13 *Oenocarpus bataua* Mart.

Uma espécie oleaginosa e comestível na região amazônica muito apreciada é a espécie *Oenocarpus bataua* Mart. (FIGURA 13) popularmente conhecida como patauí. É uma

palmeira de estipe solitário, com 4 a 26 m de altura, amplamente distribuída na Amazônia brasileira, ocorre tanto em floresta úmida de várzea e de galeria quanto em florestas de terra firme, bem adaptado a solos pobres (Galean e Bernal, 1987, Balick 1992, Moscote-Rios et al., 1998). *O. bataua* é uma planta monoica com inflorescência infra foliares que podem atingir até 2 metros de comprimento e pedúnculos florais até 40 cm (Núñez-Avellaneda e Rojasrobles, 2008). Possui de 8 a 16 folhas arrançadas em forma de espiral, cada uma medindo de 3 a 10 m de comprimento. Os folíolos são largos e pêndulos, o que facilita na identificação pelo método de fotointerpretação.

A população natural de *O. bataua* produz anualmente cerca de 39 kg por palmeira ( $\sim 350 \text{ kg.ha}^{-1}.\text{ano}$ ), podendo gerar rendas substanciais e ecologicamente sustentáveis às comunidades amazônicas (Miller, 2002). Da poupa do fruto é produzido o chamado “vinho do patauá”, o qual é bastante nutritivo e do vinho é extraído o óleo, o qual pode substituir o azeite de oliva na culinária, por ter sabor e composição química semelhante.



FIGURA 13 - *Oenocarpus bataua* (PATAUÁ) OBSERVADO A PARTIR DO SOLO (ESQUERDA, FOTO: GUILLAUME LÉOTARD) E POR IMAGEM AÉREA (DIREITA).



FONTE: o autor (2025).

### 3.2.14 *Socratea exorrhiza* (Mart.) H.Wendl.

A palmeira *Socratea exorrhiza* (Mart.) H.Wendl. (paxiuba) (FIGURA 14) é amplamente distribuída, desde o sul da Nicarágua na América Central até regiões da América do Sul, incluindo o Brasil (Dransfield et al., 2008), onde ocorre nos estados do Acre, Amapá, Amazonas, Pará, Maranhão e Roraima. Adaptada a uma variedade de habitats amazônicos, a espécie prospera em florestas de terra firme e áreas sazonalmente inundáveis, especialmente próximas a rios e córregos. Além de sua notável estrutura de raízes-escora, que podem alcançar até 4 metros de altura, essa palmeira atinge entre 10 e 25 metros e destaca-se por seu potencial ornamental e funcional (Avalos et al., 2019). Seu estipe é utilizado em construção civil para assoalhos e paredes, e na fabricação de móveis, utensílios domésticos e artesanatos. Suas sementes são valorizadas na produção de biojoias, como colares, brincos e anéis, e tanto as folhas quanto as raízes aéreas têm usos medicinais.



FIGURA 14 - *Socratea exorrhiza* (PAXIUBA) OBSERVADO A PARTIR DO SOLO (ESQUERDA, FOTO: DESERT MAX) E POR IMAGEM AÉREA (DIREITA).



FONTE: o autor (2025).

### 3.3 FITOFISIONOMIA FLORESTAL

A cobertura vegetal da Amazônia brasileira apresenta uma notável diversidade fisionômica, refletindo a complexidade ambiental da região. Embora o bioma seja frequentemente percebido como uma extensa floresta contínua, estudos apontam uma estrutura bastante heterogênea composta por múltiplas formações vegetais, influenciadas por fatores como relevo, solo, hidrologia e clima (Higuchi & Higuchi, 2012; Rizzini et al., 1988). As principais formações florestais da região são a Floresta Ombrófila Densa e a Floresta Ombrófila Aberta, que juntas representam aproximadamente 78% da vegetação original do bioma (IBGE, 2021a). A Floresta Ombrófila Densa predomina em áreas com precipitação elevada e constante, enquanto a Floresta Ombrófila Aberta ocorre geralmente em regiões com períodos de estiagem mais definidos (Veloso et al., 1991).

Além dessas, outras tipologias vegetacionais desempenham papel importante no funcionamento ecológico da Amazônia. As campinaranas, por exemplo, ocorrem em áreas com solos arenosos e mal drenados, caracterizando-se por fisionomias que vão de florestadas a arbustivas, somando cerca de 5% da área total do bioma (Carvalho, 2021; IBGE, 2021a). As savanas, embora mais restritas, também estão presentes, especialmente nas porções sul e leste da região, e apresentam variações que incluem formações arbustivas, florestadas e parques (Higuchi & Higuchi, 2012). As formações pioneiras, geralmente associadas a áreas de influência fluvial, lacustre ou marinha, contribuem ainda para a regeneração natural e para a dinâmica ecológica da floresta (IBGE, 2012).

A classificação e o mapeamento das fitofisionomias amazônicas seguem as diretrizes do Manual Técnico da Vegetação Brasileira (IBGE, 2012), fundamentando-se na metodologia proposta por Veloso, Rangel Filho e Lima (1991). O levantamento dessas formações vegetais, como apresentado por Carvalho (2021), utiliza dados vetoriais georreferenciados e imagens TM-Landsat, permitindo análises em escala adequada para o planejamento ambiental. Ao considerar a composição florística, a densidade do dossel, a altura das espécies dominantes e os gradientes ambientais, é possível reconhecer formações como florestas aluviais, de terras baixas, submontanas, montanas e alto-montanas, cada uma com características ecológicas particulares e funções distintas nos ciclos biogeoquímicos da região (Higuchi & Higuchi, 2012; Rizzini et al., 1988). Essa complexidade estrutural é essencial para a manutenção da biodiversidade, dos serviços ecossistêmicos e da resiliência ecológica da maior floresta tropical do planeta.

### 3.4 A AEROFOTOGRAMETRIA E AS AERONAVES REMOTAMENTE PILOTADAS (RPAS)

A fotogrametria, técnica que permite a obtenção de medidas e informações espaciais por meio de fotografias, evoluiu significativamente desde seu surgimento no século XIX com os experimentos de Albrecht Meydenbauer. Inicialmente utilizada com câmeras embarcadas em aeronaves tripuladas, a fotogrametria dependia de recursos logísticos e financeiros elevados, além de profissionais especializados. O advento das aeronaves remotamente pilotadas (RPAs), popularmente conhecidas como drones, representou uma transformação no campo da fotogrametria, tornando os levantamentos mais acessíveis, ágeis e seguros (Albertz, 2001; Cassemiro & Pinto, 2014). A combinação dessa tecnologia com o avanço de softwares de processamento de imagens, como os que utilizam a técnica Structure from Motion (SfM),

permite hoje a geração de modelos tridimensionais precisos com custos operacionais reduzidos (Luhmann et al., 2014; Wolf et al., 2014).

A principal diferença entre os sistemas de sensoriamento remoto baseados em satélites, aviões e drones está na resolução espacial e na flexibilidade operacional. Satélites e aviões permitem o monitoramento em larga escala, porém apresentam limitações quanto à resolução temporal e espacial, além de dependerem de condições climáticas favoráveis (Adam et al., 2010; Gomez et al., 2019). Já os drones oferecem imagens de alta resolução (até 1 cm GSD, *Ground Sample Distance*), são facilmente operáveis em áreas de difícil acesso e proporcionam uma coleta de dados com alta frequência temporal, o que é particularmente vantajoso para o monitoramento da vegetação e mudanças fenológicas (Bagaram et al., 2018; Singh & Frazier, 2018). Equipados com sensores RGB, multiespectrais, térmicos ou LiDAR, os RPAs têm sido aplicados com sucesso na ecologia de plantas, identificação de espécies, mensuração de altura de árvores, estimativas de biomassa e carbono e em levantamentos de cobertura vegetal (Wallace et al., 2016; Abdullah et al., 2021).

A facilidade de operação é outro fator decisivo para a popularização dos drones em estudos ambientais. Diferentemente das plataformas convencionais, muitos modelos de drones não exigem infraestrutura para decolagem e pouso e podem ser operados por profissionais com treinamento básico. Além disso, o processamento das imagens obtidas tornou-se mais acessível com softwares intuitivos e integrados, como o Pix4D e o Agisoft Metashape, que automatizam etapas como ortorretificação, mosaico de imagens, geração de modelos digitais de superfície e nuvens de pontos (Gil-Docampo et al., 2020; Formoso et al., 2019). Essa praticidade tem impulsionado o uso dos drones em pesquisas voltadas à conservação ambiental, manejo florestal e fiscalização de áreas degradadas, inclusive em regiões remotas da Amazônia (Fontes & Pozzetti, 2016; Torresan et al., 2017).

No Brasil, a operação de RPAs é regulamentada pela Agência Nacional de Aviação Civil (ANAC) e pelo Departamento de Controle do Espaço Aéreo (DECEA). A norma vigente define limites operacionais como altitude máxima de 120 metros para voos sem licença especial, além de proibições de voos em áreas densamente povoadas ou próximas a aeródromos sem autorização específica. Para voos experimentais ou científicos, como os realizados por universidades e institutos de pesquisa, é exigido o Certificado de Autorização de Voo Experimental (CAVE) emitido pela ANAC. Também é necessário solicitar permissão de voo aos órgãos regionais do DECEA, conforme a localidade da operação (AIC 21/10 – ANAC, 2021). O cumprimento dessas exigências assegura a segurança das operações e a

confiabilidade dos dados obtidos, além de permitir que os drones sejam utilizados de forma responsável na pesquisa ambiental e no mapeamento da vegetação brasileira.

### 3.5 REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais (RNAs) são modelos computacionais inspirados no funcionamento do cérebro humano, compostos por unidades de processamento interligadas, chamadas de neurônios artificiais ou nodos. A ideia central é reproduzir, de forma simplificada, a capacidade dos sistemas biológicos de aprender com a experiência e generalizar informações. O conceito de RNA surgiu com o trabalho pioneiro de McCulloch e Pitts (1943), que introduziram um modelo lógico de neurônio artificial. A evolução da área incluiu contribuições de Hebb (1949) sobre aprendizado sináptico, o Perceptron de Rosenblatt (1958) para aprendizado supervisionado e o algoritmo de retropropagação (backpropagation) apresentado por Rumelhart, Hinton e Williams na década de 1980, que revolucionou o treinamento de redes multicamadas (Hopfield, 1982; BINOTI et al., 2013).

A arquitetura de uma RNA é composta por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. Cada neurônio recebe sinais ponderados por pesos sinápticos e uma constante de polarização (bias), sendo processados por uma função de ativação que introduz não linearidade ao sistema (WANG, 2003). As funções mais comuns incluem a sigmoide, tangente hiperbólica e ReLU, cada uma com características específicas de desempenho e convergência. O treinamento das RNAs envolve o ajuste iterativo dos pesos, com base no erro entre a saída obtida e a desejada, geralmente utilizando algoritmos como a Regra Delta ou o próprio backpropagation. Esse processo permite que a rede "aprenda" padrões e relacione variáveis de entrada e saída de maneira eficaz, mesmo em sistemas altamente complexos e não lineares.

As RNAs têm sido amplamente utilizadas em aplicações como classificação de padrões, previsão de séries temporais, reconhecimento de imagens e, mais recentemente, em sistemas de visão computacional acoplados a sensores remotos e drones (Mu et al., 2018; Lopez-Jimenez et al., 2019). No contexto da ecologia de plantas, redes neurais vêm sendo empregadas para detectar indivíduos arbóreos, estimar atributos estruturais como altura e biomassa, além de realizar o mapeamento de espécies com alta acurácia. Com o advento do deep learning, caracterizado pelo uso de redes com múltiplas camadas ocultas, surgiram avanços expressivos na capacidade de reconhecimento e generalização de padrões complexos, impulsionando áreas como a inteligência artificial aplicada à classificação de vegetação por imagens aéreas (Valbuena et al., 2020; Zou et al., 2019). Essa sinergia entre sensores de alta



resolução e RNAs tem se mostrado promissora para o monitoramento florestal em larga escala e a tomada de decisão baseada em dados.

### 3.6 REDES NEURAIAS CONVOLUCIONAIS

As Redes Neurais Convolucionais (CNNs, do inglês *Convolutional Neural Networks*) constituem uma das arquiteturas mais expressivas e eficazes dentro do campo do aprendizado profundo (*deep learning*), notadamente no processamento de dados visuais. Inspiradas na estrutura hierárquica do córtex visual de mamíferos, as CNNs utilizam camadas convolucionais para capturar automaticamente padrões espaciais locais em imagens, preservando a relação entre os pixels vizinhos (Fukushima, 1980; LeCun et al., 1998). Essa capacidade torna as CNNs amplamente aplicáveis em tarefas como classificação de imagens, segmentação semântica, detecção de objetos e reconhecimento facial (Krizhevsky et al., 2012; Simonyan & Zisserman, 2014).

Diferentemente das redes neurais totalmente conectadas, as CNNs compartilham pesos entre os filtros convolucionais, o que reduz o número de parâmetros a serem treinados e melhora a generalização do modelo (Goodfellow et al., 2016). Além disso, camadas de pooling (como *max-pooling*) são empregadas para reduzir a dimensionalidade dos mapas de ativação, proporcionando invariância a pequenas translações e deformações nas imagens de entrada (LeCun et al., 1998). Funções de ativação não lineares, como a ReLU (*Rectified Linear Unit*), são essenciais para permitir a modelagem de relações complexas entre os dados (Nair & Hinton, 2010), e o uso de arquiteturas profundas possibilita a extração de representações de alto nível progressivamente mais abstratas.

O sucesso das CNNs se deve a diversos fatores convergentes, como o aumento do poder computacional (notadamente o uso de GPUs), a disponibilização de grandes conjuntos de dados anotados, como ImageNet e MSCOCO, por exemplo, e melhorias em técnicas de regularização e inicialização de pesos (Krizhevsky et al., 2012; He et al., 2016). Modelos como AlexNet, VGGNet, ResNet e EfficientNet elevaram o desempenho em tarefas de visão computacional, sendo amplamente utilizados em áreas como diagnóstico médico, agricultura de precisão, sensoriamento remoto e sistemas autônomos (Tan & Le, 2019; Esteva et al., 2017; Kamilaris & Prenafeta-Boldú, 2018).

Apesar do desempenho notável, as CNNs ainda enfrentam limitações importantes. O treinamento supervisionado requer grandes volumes de dados rotulados, o que pode ser inviável em certos domínios. Além disso, essas redes não lidam bem com transformações

geométricas complexas, como rotações e mudanças de escala (Sabour et al., 2017). Estratégias recentes têm buscado superar essas limitações, como o uso de *transfer learning*, redes cápsulas (*capsule networks*), mecanismos de atenção espacial e métodos de interpretabilidade para explicar as decisões dos modelos (Zhou et al., 2016; Vaswani et al., 2017; Ribeiro et al., 2016). Assim, as CNNs continuam sendo uma base essencial na fronteira entre inteligência artificial e percepção visual computacional.

### 3.7 YOLOV10X

Desde sua introdução por Joseph Redmon em 2016, a arquitetura YOLO (*You Only Look Once*) revolucionou a detecção de objetos ao substituir abordagens mais lentas e complexas, como R-CNN e Faster R-CNN, por um método de detecção em uma única etapa. O YOLOv1 já demonstrava eficiência ao prever diretamente as coordenadas dos objetos em uma única passagem pela rede, tornando-se a primeira solução viável para aplicações em tempo real (Redmon *et al.*, 2016). As versões seguintes, YOLOv2 e YOLOv3, trouxeram melhorias na precisão e generalização, adicionando detecção em múltiplas escalas e aprimoramentos estruturais, como camadas de caminho residual (Redmon & Farhadi, 2018). A partir do YOLOv4, desenvolvido por Alexey Bochkovskiy, a arquitetura se tornou ainda mais robusta, introduzindo otimizações como a adição de *Mish activation* e técnicas avançadas de *data augmentation*, permitindo melhor adaptação a diferentes cenários e tornando-se popular em aplicações como monitoramento de tráfego e imagens médicas (Bochkovskiy et al., 2020). Estudos recentes têm adotado o modelo YOLOv4 para a detecção de espécies de palmeiras, recursos de grande importância social e econômica para as comunidades locais da Amazônia. No entanto, devido à alta complexidade estrutural e florística das florestas tropicais, a maioria dessas pesquisas tem se concentrado em áreas isoladas e de menor escala. Essa limitação dificulta a obtenção de dados essenciais para o manejo e planejamento comercial dessas espécies, como informações sobre densidade populacional e padrões de distribuição espacial. Karasinski et al. (2021) avaliaram o desempenho do YOLOv4 na detecção e classificação automática de palmeiras em um remanescente de Floresta Ombrófila Aberta no sudoeste da Amazônia, utilizando imagens de UAVs. O estudo demonstrou que o modelo alcançou uma precisão média geral de 91,08%, com desempenhos variando entre 92,07% e 96,2%, dependendo da espécie analisada, tornando-se uma ferramenta promissora para o mapeamento e manejo dessas florestas).

A evolução seguiu com o YOLOv5, criado pela Ultralytics, que trouxe melhorias na eficiência computacional e facilidade de implementação, tornando-se uma das versões mais

amplamente utilizadas (Jocher et al., 2021). Posteriormente, o YOLOv6 e YOLOv7 refinaram a estrutura da rede para aumentar a precisão sem comprometer a velocidade, otimizando camadas convolucionais e incorporando estratégias aprimoradas de treinamento (Wang et al., 2022; Wang et al., 2023). As versões mais recentes, como YOLOv8, YOLOv9 e YOLOv10, representam o estado da arte em modelos de detecção de objetos, integrando técnicas de aprendizado profundo avançadas, como detecção sem caixa de ancoragem (*anchor-free*), que permite identificar objetos diretamente, sem depender de caixas pré-definidas, tornando o processo mais flexível e preciso, especialmente para objetos pequenos ou de formatos variados. Além disso, reduzem a necessidade de aplicar etapas posteriores de filtragem (como a supressão não máxima, usada para eliminar caixas duplicadas), o que simplifica o processamento e melhora a velocidade e também incluem aprimoramentos no processamento paralelo para maximizar a precisão em tempo real. Essas versões mais modernas expandiram as aplicações do YOLO para novas áreas, como sensoriamento remoto, onde a detecção de pequenos objetos e a eficiência computacional são cruciais.

O YOLOv10 foi lançado como um avanço significativo na arquitetura da série, trazendo melhorias em eficiência, escalabilidade e precisão, especialmente para a detecção de pequenos objetos. Sua arquitetura foi reformulada para melhor lidar com imagens de alta resolução e permitir um processamento mais eficiente, o que o torna altamente aplicável em contextos como sensoriamento remoto, drones, veículos autônomos e vigilância inteligente. Um dos destaques do YOLOv10 é a otimização na alocação de recursos computacionais, garantindo uma melhor relação entre velocidade e precisão, sem a necessidade de hardware de alto desempenho. Além disso, o modelo aprimorou sua estrutura de *backbone* e *neck*, tornando-se mais eficaz na detecção de alvos em múltiplas escalas e em diferentes condições de iluminação e perspectiva (Nguyen & Huynh-The, 2025).

Dentro do contexto do sensoriamento remoto, o YOLOv10 se mostrou especialmente promissor para aplicações como monitoramento ambiental e análise de imagens de satélite. Modelos derivados, como o RS-YOLOv10, foram desenvolvidos para aprimorar a detecção de objetos pequenos, como veículos, embarcações e edifícios em imagens de alta altitude, resolvendo um dos principais desafios do processamento de imagens aéreas (Xie et al., 2024). Outras variações, como o SOD-YOLOv10, foram criadas para aprimorar a segmentação de alvos complexos em imagens de drones e sensores multiespectrais, garantindo maior precisão mesmo em áreas com sobreposição visual e ruídos atmosféricos (Sun et al., 2025). Esses

avanços tornaram o YOLOv10 uma ferramenta poderosa para aplicações de geoprocessamento, segurança pública e monitoramento de desastres naturais.

Além de suas capacidades aprimoradas, o YOLOv10 incorpora novas funções de perda, como SIOU Loss, que melhora a detecção ao calcular a proximidade e sobreposição dos objetos com maior precisão (Do et al., 2024). A integração com novas técnicas de visão computacional baseada em transformers, como *End-to-end object detection with transformers* (DETR) (Carion et al., 2020), também abre novas possibilidades para tornar a detecção de objetos ainda mais precisa, especialmente em imagens de baixa qualidade ou altamente dinâmicas. Com essas melhorias, o YOLOv10 e suas variantes consolidam-se como uma das arquiteturas mais avançadas para detecção de objetos em tempo real, sendo amplamente utilizado para vigilância aérea, agricultura de precisão, análise urbana e estudos ambientais. A tendência para o futuro é a incorporação de estratégias ainda mais sofisticadas de aprendizado profundo, garantindo um desempenho superior em uma variedade de cenários e aplicações.



# CAPÍTULO I

## DETECÇÃO AUTOMÁTICA DE PALMEIRAS A PARTIR DE IMAGENS RGB OBTIDAS POR AERONAVES REMOTAMENTE PILOTADAS NA AMAZÔNIA E YOLOV10X.

### RESUMO

A floresta amazônica abriga uma diversidade excepcional de palmeiras, muitas das quais possuem grande relevância ecológica, econômica e sociocultural. No entanto, a quantificação da distribuição espacial e da densidade dessas espécies em larga escala ainda representa um desafio, em razão da complexidade estrutural da floresta e das limitações logísticas para coleta de dados. Este estudo avaliou o desempenho do modelo de *deep learning* YOLOv10x para detecção e classificação de palmeiras economicamente importantes a partir de imagens RGB obtidas por drones em 47 locais da Amazônia ocidental (Acre, Rondônia, Roraima e Amazonas). Utilizou-se um conjunto de 26.713 imagens anotadas, totalizando 61.894 indivíduos de 14 espécies de palmeiras, para o treinamento e validação do modelo por meio de validação cruzada com 3 *folds*. Foram comparados modelos regionais e um modelo global, destacando-se o modelo global, com mAP médio de 80% e F1-score de 79%, demonstrando boa capacidade de generalização entre diferentes contextos ambientais. No entanto, persistem limitações na distinção entre espécies do mesmo gênero, como tucumã e jauari (*Astrocaryum aculeatum* vs. *Astrocaryum jauari*), como também inajá e urucuri (*Attalea maripa* vs. *Attalea phalerata*), devido à semelhança morfológica. Esses casos de confusão reforçam a necessidade de ampliar a diversidade dos dados de treinamento, garantindo melhor representação das variações entre espécies e melhorando a precisão do modelo.

**Palavras-chave:** Detecção de palmeiras, Inteligência Artificial, drones, Floresta Amazônica

## ABSTRACT

The Amazon rainforest harbors an exceptional diversity of palm species, many of which hold significant ecological, economic, and sociocultural importance. However, quantifying the spatial distribution and density of these species at large scales remains a challenge due to the forest's structural complexity and the logistical constraints of field data collection. This study evaluated the performance of the YOLOv10x deep learning model for detecting and classifying economically important palms using RGB images captured by drones at 47 locations across the western Amazon (Acre, Rondônia, Roraima, and Amazonas). A dataset of 26,713 annotated images was used, totaling 61,894 individual palms from 14 species, for training and validating the model through 3-fold cross-validation. Regional models were compared with a global model, with the global model achieving superior performance, showing a mean average precision (mAP) of 80% and an F1-score of 79%, demonstrating strong generalization across different environmental contexts. However, limitations persist in distinguishing species within the same genus, such as tucumã and jauari (*Astrocaryum aculeatum* vs. *Astrocaryum jauari*), as well as inajá and urucuri (*Attalea maripa* vs. *Attalea phalerata*), due to morphological similarity. These confusion cases highlight the need to expand the diversity of training data to better capture interspecific variation and improve model accuracy.

**Keywords:** Palm tree detection, Artificial Intelligence, UAV, Amazon Rainforest

## 1 INTRODUÇÃO

A Floresta Amazônica é um dos ecossistemas mais biodiversos do planeta e desempenha um papel crucial na provisão de recursos florestais não madeireiros, especialmente aqueles derivados das palmeiras. Esses recursos incluem frutos, óleos, fibras e resinas, que possuem grande importância econômica e cultural para as comunidades locais e para a bioeconomia regional. Nas últimas décadas, esses produtos deixaram de ser exclusivamente parte da economia local para atingir mercados nacionais e internacionais, impulsionados por uma crescente industrialização e valorização da biodiversidade amazônica. O açaí (*Euterpe precatoria*), por exemplo, tornou-se um dos produtos amazônicos mais demandados globalmente, sendo amplamente utilizado na indústria de bebidas, suplementos energéticos e alimentos funcionais, devido ao seu alto teor de antioxidantes (Pacheco *et al.*, 2018). O óleo de pataúá (*Oenocarpus bataua*), tradicionalmente consumido por comunidades locais, agora integra formulações da indústria cosmética por suas propriedades hidratantes e regeneradoras, sendo encontrado em cremes, shampoos e óleos corporais. O buriti (*Mauritia flexuosa*) tem se destacado na indústria de cosméticos e farmacêutica devido à sua alta concentração de carotenoides e vitamina A, sendo utilizado em protetores solares e produtos dermatológicos (Albuquerque *et al.*, 2005, Melo *et al.*, 2024). Já o babaçu (*Attalea speciosa*), antes restrito a sistemas agroextrativistas regionais, ganhou relevância na produção de biodiesel, biolubrificantes e cosméticos, além de ser aproveitado na indústria alimentícia e de higiene (Santos *et al.*, 2023). Esse avanço na escala produtiva e comercial representa uma oportunidade econômica para a região, mas também demanda estratégias de manejo sustentável para evitar impactos ambientais e garantir a conservação dessas espécies (Homma, 2012; Shanley *et al.*, 2012).

A crescente pressão sobre os ecossistemas amazônicos, impulsionada pelo desmatamento, pela conversão do uso da terra e pela exploração predatória de recursos naturais, ameaça a biodiversidade e compromete a oferta de serviços ecossistêmicos. Nesse contexto, torna-se fundamental promover alternativas de desenvolvimento que conciliem a conservação ambiental com a geração de renda. A valorização de produtos florestais não madeireiros, especialmente os derivados de palmeiras, configura uma estratégia promissora, ao reunir potencial de mercado e sustentabilidade ecológica, dada sua ampla aplicabilidade nas indústrias alimentícia, cosmética, farmacêutica e energética (Mabetana *et al.*, 2024). No entanto, conciliar o desenvolvimento econômico com a conservação ambiental exige superar

importantes desafios ligados à quantificação e manejo desses recursos em uma escala mais ampla.

A estrutura complexa das florestas tropicais, marcada por densa vegetação, alta diversidade biológica e sobreposição de copas, dificulta a obtenção de dados precisos sobre a distribuição e abundância de espécies com potencial econômico, como muitas palmeiras. Soma-se a isso a dispersão natural das populações, a sazonalidade dos produtos, a baixa produtividade da extração devido aos obstáculos logísticos associados à coleta, transporte e beneficiamento (Freitas et al., 2017; Homma, 2021a). A ausência de informações detalhadas e espacializadas compromete a elaboração de políticas públicas, estratégias de manejo sustentável e investimentos consistentes no fortalecimento da bioeconomia regional (Homma, 2021b). Ademais, a dificuldade de quantificar o potencial produtivo por meio de métodos tradicionais leva muitos produtores a descartarem áreas que, embora subestimadas, podem revelar-se promissoras para a extração sustentável.

Para superar essas limitações, torna-se cada vez mais necessário adotar métodos inovadores e tecnologias avançadas. O sensoriamento remoto por meio de aeronaves remotamente pilotadas (RPA) oferece uma alternativa eficiente, especialmente por sua capacidade de capturar imagens de alta resolução em áreas remotas e de difícil acesso. Essas imagens permitem gerar ortomosaicos detalhados, capazes de revelar padrões sutis na vegetação e auxiliar na identificação de espécies específicas (Figueiredo et al., 2020; Ferreira et al., 2020; Casapia et al., 2025; Karasinski et al. 2025). Além disso, quando integradas a algoritmos de aprendizado profundo, como redes neurais convolucionais, essas imagens se tornam ferramentas poderosas para a análise automatizada da paisagem florestal, possibilitando a quantificação em larga escala com maior precisão e agilidade (Wagner et al., 2020; Casapia et al., 2025; Karasinski et al., 2025).

Entre os métodos de detecção, destaca-se a família de algoritmos *You Only Look Once* (YOLO), amplamente adotada em tarefas de detecção de objetos em tempo real devido à sua eficiência e acurácia. Uma das versões mais recente, YOLOv10 (Wang et al., 2024), apresenta aprimoramentos em desempenho computacional e precisão de detecção, permitindo aplicações mais robustas em ambientes complexos e com grande variabilidade visual, como florestas tropicais. Essa combinação entre alta resolução espacial, flexibilidade operacional dos drones e capacidade de processamento inteligente tem potencial para suprir lacunas críticas nos inventários florestais convencionais, sobretudo no que diz respeito à identificação de espécies com importância ecológica e econômica, como muitas palmeiras nativas.



No entanto, a implementação efetiva dessas tecnologias enfrenta desafios significativos, principalmente relacionados à qualidade e variabilidade dos dados utilizados no treinamento dos modelos. A obtenção de dados representativos na Amazônia é limitada por fatores como a dificuldade de acesso, a cobertura densa do dossel, a variabilidade fenológica e a alta biodiversidade, o que restringe tanto a coleta de imagens quanto a anotação precisa das espécies-alvo. Além disso, a heterogeneidade espacial e temporal da floresta torna essencial o uso de conjuntos de dados diversos e de alta qualidade para garantir a capacidade de generalização dos modelos de detecção. Métodos tradicionais baseados em características manuais apresentam desempenho limitado em ambientes florestais complexos, sendo progressivamente substituídos por abordagens baseadas em redes neurais convolucionais (CNNs), que permitem maior robustez na detecção mesmo em cenários desafiadores. Nesse sentido, o uso de modelos como YOLOv10 (Wang *et al.*, 2024), treinados com dados regionais e variados, pode representar um avanço significativo no monitoramento automatizado da vegetação amazônica e na quantificação do potencial produtivo de espécies de palmeiras de interesse para a bioeconomia.


Diante desse contexto, o objetivo deste estudo foi avaliar o efeito da variação espacial entre sítios no desempenho do modelo YOLOv10x na detecção e classificação de palmeiras economicamente importantes, utilizando imagens RGB de alta resolução obtidas por drones na Amazônia brasileira. Especificamente, busca-se compreender se a diversidade ambiental e ecológica entre diferentes regiões exige o desenvolvimento de modelos treinados localmente, adaptados às condições específicas de cada sítio, ou se um modelo global seria suficientemente robusto para generalizar com precisão a detecção das espécies em diferentes contextos florestais.

## 2 MATERIAL E MÉTODOS

### 2.1 LOCALIZAÇÃO E CARACTERIZAÇÃO FÍSICA DA ÁREA DE ESTUDO

O estudo foi conduzido na Região Amazônica Ocidental, abrangendo os estados do Acre, Amazonas, Rondônia e Roraima (FIGURA 15). Faz parte do projeto Geoflora (21149.000754/2022-79), que se dedica às geotecnologias aplicadas à automação florestal e espacialização dos estoques de carbono em áreas de floresta nativa na Amazônia Ocidental. O Geoflora é uma iniciativa da Empresa Brasileira de Pesquisa Agropecuária (Embrapa) Acre com apoio do Fundo JBS pela Amazônia (FJBSA). A sede da Embrapa Acre está localizada no município de Rio Branco, estado do Acre, especificamente no trecho Rio Branco – Porto Velho, RO, à margem direita da BR 364 - Km 14, com coordenadas geográficas de 10° 01' 22" S e 67° 40' 3" W.

FIGURA 15 - LOCALIZAÇÃO DA ÁREA DE ESTUDO. EM VERDE ÁREA OCUPADA POR FLORESTA, EM AMARELO ÁREA DE TRANSIÇÃO DE FLORESTA PARA CERRADO, NOS ESTADOS DA AMAZÔNIA LEGAL. OS PONTOS REPRESENTAM CADA SÍTIO NOS QUAIS AS IMAGENS FORAM OBTIDAS.



FONTE: o autor (2025).

O clima no estado do Acre, segundo classificação de Köppen é do tipo Am, clima tropical de monções, com período seco anual de 3 meses, nas regionais do Baixo e Alto Acre e, do tipo Af, clima de floresta tropical equatorial sem estação seca, no restante do Estado

(Alvares, 2013; Cunha e Duarte, 2005; IBGE, 1997), com temperatura e precipitação média anual de 24,3 °C e 1.950 mm, respectivamente. Segundo IBGE (2023) as tipologias florestais encontradas no Estado do Acre são: Floresta Aberta com Bambu Dominante (9,40%), Floresta Aberta com bambu mais Floresta Aberta com Palmeiras (26,20%), Floresta Aberta com Palmeiras das Áreas Aluviais (5,48%), Floresta Aberta com Palmeiras (7,77%), Floresta Aberta com Palmeiras e Floresta Densa (12,12%), Floresta Densa mais floresta Aberta com Palmeiras (7,20%), Floresta Aberta com Palmeiras mais Floresta Aberta com Bambu (21,02%) Floresta Aberta com Bambu em Áreas Aluviais (2,04%), Floresta Densa (0,53%), Floresta com Bambu mais Floresta Densa (0,36%) e Floresta Densa Submontana (0,47%).

Rondônia possui um clima predominantemente tropical de monções (Am) (Alvares, 2013), com temperaturas médias anuais que variam entre 23,2°C e 26°C. A precipitação anual no estado oscila entre 1.340 mm e 2.340 mm, com menores valores de precipitação no Sudeste do estado e aumentando gradativamente em direção ao Norte (Franca; Embrapa, 2015) e a estação seca é curta, com duração de até três meses (precipitação média em junho e julho inferior a 50 mm/mês) o que mantém a umidade relativa elevada e favorece a cobertura florestal densa, especialmente nas áreas mais ao norte. As principais tipos de vegetação encontrados são: Floresta Ombrófila Aberta (Aluvial, das Terras Baixas, Submontanas, com Palmeiras e Bambu, respectivamente) (75%), Floresta Ombrófila Densa (Aluvial, das Terras Baixas, Submontana, com dossel uniforme e com dossel emergente, respectivamente) (15%), Savanas (Florestadas, Arborizadas, Parque ) (5%) e ainda regiões de Floresta Estacional Semidecidual (Aluvial, das Terras Baixas, Submontana, com dossel uniforme e com dossel emergente, respectivamente) (4%).

O estado do Amazonas apresenta um regime pluviométrico com índices superiores a 2000 mm, proporcionando condições ideais para o desenvolvimento de florestas densas e biodiversidade rica. O clima predominante é do tipo Af (Clima Tropical equatorial), principalmente na porção Norte e do tipo Am na porção Sul do Estado. As temperaturas variam entre 25°C e 27°C. As principais regiões fitoecológicas encontradas no são: Floresta Ombrófila Densa (Aluvial, das Terras Baixas, Submontana e Montana) (70 a 75%), Floresta Ombrófila Aberta (Aluvial, das Terras Baixas, Submontana) (10 a 15%), Campinarana (Florestada, Arborizada, Arbustiva) (5%) e ainda são encontradas pequenas manchas de savana ao sul e leste do estado (1%).

O estado de Roraima apresenta uma diferenciação climática interessante em relação ao restante da Amazônia Ocidental, com regiões de clima tropical equatorial (Af)

predominantemente ao Norte e áreas de savana que possuem uma estação seca mais prolongada. As temperaturas médias anuais situam-se entre 25°C e 27°C, com a precipitação anual variando de 1.500 mm nas áreas de savana até 1.800 mm nas regiões de floresta. Esta variação climática impacta diretamente a cobertura vegetal, criando mosaicos de floresta densa e áreas mais abertas de savana. As principais formações fitoecológicas encontradas para o estado são: Floresta Ombrófila Densa (Aluvial, de Terras Baixas, Submontana e Montana, com dossel uniforme, emergente respectivamente), Campinarana (Florestada, Arborizada, e Arbustiva, com e sem palmeiras respectivamente) Floresta Ombrófila Densa (Submontana, com dossel uniforme, emergente e com cipó) e Savana Arborizada sem floresta de galeria.

## 2.2 COLETA DE DADOS DE CAMPO

Diversas expedições de campo foram realizadas entre 2022 a 2024, sendo divididas em duas atividades principais: instalação de parcelas de inventário de palmeiras para validação e coleta de imagens com RPA. Inicialmente, foram instaladas parcelas 50 x 50 m em que foram mensuradas todas as palmeiras acima de 10 cm à 1,30 m do solo (DAP) e apenas os indivíduos maiores de 10 metros de altura, buscando abranger apenas os indivíduos que pudessem atingir o dossel da floresta e que pudessem ser visualizados nas imagens de drones. Destes indivíduos, foram tomadas as coordenadas geográficas com GNSS (Global Navigation Satellite System), a altura total, DAP, posição em que se encontram no dossel (copa exposta ao sol, copa parcialmente coberta, copa totalmente coberta), estado fenológico (presença de inflorescência e infrutescência) e ainda foram coletadas algumas exsiccatas e depositadas no herbário da Universidade Federal do Acre (UFAC). No entanto, ao longo das campanhas, observou-se que o delineamento com parcelas fixas não capturava adequadamente e a diversidade de espécies desejada, especialmente para palmeiras com distribuição mais restrita. Diante disso, a abordagem metodológica foi ajustada: passou-se a realizar a inspeção visual das imagens aéreas (fotoinspeção) para a identificação prévia das copas das palmeiras, principalmente daquelas espécies que não haviam sido registradas nas parcelas. A partir dessa análise, realizou-se a navegação em campo com GNSS para verificar a correspondência entre os alvos detectados nas imagens e os indivíduos reais. Essa estratégia permitiu treinar a interpretação visual das imagens, ampliar a representatividade das espécies no conjunto de dados e validar diretamente as detecções, tornando o processo mais eficiente e abrangendo a diversidade das palmeiras de interesse.

Para a coleta das imagens RGB, o RPA DJI Mavic 2 Pro e 3 Enterprise foram utilizados. Inicialmente foram solicitadas autorizações de voo em pontos estratégicos pré-



determinados, e, então, os planos foram confeccionados e executados pelos softwares Litch e Pix4D. Cada plano de voo foi executado com o tempo máximo de 17 min, a fim de prezar pela segurança de voo. As imagens foram tomadas a uma altura de voo de 120 metros, no ângulo do nadir com sobreposição lateral e longitudinal acima de 80% com velocidades de cruzeiro entre 10 a 15 m/s, garantindo uma resolução espacial de 0,04 metros por pixel. As imagens foram coletadas entre os anos de 2022 a 2024, sendo que mais de 50 mil hectares, em 47 diferentes locais (sítios), foram sobrevoados.

## 2.3 PREPARAÇÃO DO BANCO DE DADOS

### 2.3.1 Pré-processamento das imagens e demarcação das copas individuais de palmeiras

Após coletadas, as imagens foram processadas no software Pix4D, gerando ortomosaicos que serviram de base para o treinamento do YOLOv10x. Os ortomosaicos foram recortados em subpartes (*tiles*) menores com tamanho de 1536 x 1536 pixels, uma vez que demandam grande capacidade de processamento. *Tiles* com distorções geométricas ou má qualidade, como os localizados nas bordas das ortofotos (FIGURA 16), foram excluídos da base de treinamento, assegurando a integridade dos dados utilizados na modelagem

FIGURA 16 ETAPAS DE PRÉ-PROCESSAMENTO DAS IMAGENS CAPTURADAS POR RPA. (a) *TILES* COM DISTORÇÕES, BAIXA QUALIDADE OU LOCALIZADOS NAS BORDAS DAS ORTOFOTOS FORAM DESCARTADOS. (b) COPAS DEMARCADAS NO *TILE*.



FONTE: o autor (2025).

Em cada *tile*, as palmeiras foram rotuladas de acordo com a espécie de palmeira correspondente. Para a rotulagem das imagens, utilizou-se o software LabelImg (TZUTALIN, 2015). O conjunto de dados geral foi composto por 26.713 imagens rotuladas, que, a partir desse conjunto, foram organizadas em diferentes grupos para treinamento (TABELA 1 e FIGURA 17).

TABELA 1 - AGRUPAMENTO DO CONJUNTO DE DADOS POR REGIÃO.

| Grupo         | Sítios                                                                                                                                                                                                 | Tiles        | Palmeiras (Total) | Classes de detecção | Média Imagens/Classe | Média Palmeiras/Classe |
|---------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------|-------------------|---------------------|----------------------|------------------------|
| Alto Acre     | 's037', 's047'                                                                                                                                                                                         | 3147         | 7045              | 10                  | 314,70               | 704,50                 |
| Baixo Acre    | 's001', 's002', 's006', 's007', 's009', 's010', 's011', 's012', 's013', 's020', 's021', 's022', 's023', 's024', 's025', 's026', 's027', 's028', 's029', 's030', 's031', 's036', 's038', 's039', 's042' | 9488         | 19560             | 9                   | 1054,22              | 2173,33                |
| Juruá         | 's014', 's018'                                                                                                                                                                                         | 1086         | 2271              | 9                   | 120,67               | 252,33                 |
| Rondônia      | 's004', 's005', 's032', 's033', 's034', 's035', 's046'                                                                                                                                                 | 4046         | 8923              | 8                   | 505,75               | 1115,38                |
| Roraima       | 's043', 's044', 's045'                                                                                                                                                                                 | 4203         | 15677             | 8                   | 525,38               | 1959,63                |
| Sul           | 's019', 's040', 's041'                                                                                                                                                                                 | 2391         | 4062              | 8                   | 298,88               | 507,75                 |
| Amazonense    | 's003', 's008', 's015', 's016', 's017'                                                                                                                                                                 | 2352         | 4356              | 10                  | 235,20               | 435,60                 |
| Envira        |                                                                                                                                                                                                        |              |                   |                     |                      |                        |
| <b>Global</b> | <b>Todos</b>                                                                                                                                                                                           | <b>26713</b> | <b>61894</b>      | <b>15</b>           | <b>1780,87</b>       | <b>4126,27</b>         |


A TABELA 2 apresenta a lista de espécies de palmeiras identificadas na área de estudo, incluindo o código utilizado para cada uma no banco de dados, o nome comum e o nome científico correspondente.

TABELA 2 – IDENTIFICAÇÃO DAS ESPÉCIES NA ÁREA DE ESTUDO

| Código | Nome Comum              | Nome Científico                                    |
|--------|-------------------------|----------------------------------------------------|
| aa14   | tucumã                  | <i>Astrocaryum aculeatum</i> G. Mey.               |
| ab10   | jaci                    | <i>Attalea butyracea</i> (Mutis ex L.f.) Wess.Boer |
| aj82   | jauari                  | <i>Astrocaryum jauari</i> Mart.                    |
| am16   | inajá                   | <i>Attalea maripa</i> (Aubl.) Mart.                |
| ap12   | urucuri                 | <i>Attalea phalerata</i> Mart. ex Spreng.          |
| as48   | babaçu                  | <i>Attalea speciosa</i> Mart. ex Spreng.           |
| at34   | cocão                   | <i>Attalea tesmannii</i> Burret.                   |
| au13   | murumuru                | <i>Astrocaryum ulei</i> Burret.                    |
| ep01   | açaí solteiro           | <i>Euterpe precatoria</i> Mart.                    |
| ep35   | açaí solteiro produtivo | <i>Euterpe precatoria</i> Mart.                    |
| ma79   | buritirana              | <i>Mauritiella armata</i> (Kunth) Burret.          |
| mf09   | buriti                  | <i>Mauritia flexuosa</i> L. f.                     |
| ob19   | patauá                  | <i>Oenocarpus bataua</i> Mart.                     |
| ob70   | bacaba                  | <i>Oenocarpus bacaba</i> Mart.                     |
| se04   | paxiúba                 | <i>Socratea exorrhiza</i> (Mart.) H.Wendl.         |

Para compreender a composição e a abrangência do conjunto de dados utilizado neste estudo, foi realizada uma análise exploratória considerando tanto a distribuição das espécies quanto sua presença nas diferentes regiões amostradas. A visualização apresentada na FIGURA 17 permite identificar quais espécies de palmeiras são mais frequentes e como estão distribuídas espacialmente, o que é fundamental para avaliar a representatividade do *dataset*.

FIGURA 17 - FORMAÇÃO DO *DATASET* UTILIZADO PARA O ESTUDO. (A) DISTRIBUIÇÃO DOS DADOS POR ESPÉCIES DE PALMEIRAS ESTUDADAS E POR REGIÃO. (B) RELAÇÃO DA OCORRÊNCIA DAS ESPÉCIES NAS DIFERENTES REGIÕES ILUSTRADA POR UM DIAGRAMA DE SANKEY, EVIDENCIANDO A CONEXÃO ENTRE AS ESPÉCIES E SUAS RESPECTIVAS REGIÕES GEOGRÁFICAS. aa14 – TUCUMÃ (*Astrocaryum aculeatum*), ab10 – JACI (*Attalea butyracea*), aj82 – JAUARI (*Astrocaryum jauari*), am16 – INAJÁ (*Attalea maripa*), ap12 – URUCURI (*Attalea phalerata*), as48 – BABAÇU (*Attalea speciosa*), at34 – COCÃO (*Attalea tessmannii*), au13 – MURUMURU (*Astrocaryum ulei*), ep01 – AÇAÍ SOLTEIRO (*Euterpe precatoria*), ep35 – AÇAÍ PRODUTIVO (*Euterpe precatoria*), se04 – PAXIUBA (*Socratea exorrhiza*), ma79 – BURITIRANA (*Mauritiella armata*), mf09 – BURITI (*Mauritia flexuosa*), ob70 – BACABA (*Oenocarpus bacaba*), ob19 – PATAUÁ (*Oenocarpus bataua*).




FONTE: o autor (2025).

### 2.3.2 Demarcação das copas individuais

A anotação das copas individuais das palmeiras foi realizada manualmente a partir de ortofotos geradas por RPA utilizando ferramentas específicas para rotulagem de objetos, como o software LabelImg. Cada copa das palmeiras visíveis nas imagens RGB foi delimitada por uma caixa delimitadora retangular (*bounding box*), de acordo com as diretrizes do formato YOLO (FIGURA 18). As coordenadas das caixas foram exportadas no formato YOLO, que representa cada anotação por uma linha contendo a classe da palmeira (codificada por um número inteiro) seguida das coordenadas normalizadas do centro da caixa e suas dimensões relativas (largura e altura) ao tamanho da imagem em pixels, todas variando entre 0 e 1. Esse conjunto anotado foi então utilizado como base para o treinamento supervisionado dos modelos de detecção.

FIGURA 18 - DEMARCAÇÃO DAS COPAS INDIVIDUAIS DE PALMEIRAS NAS IMAGENS, EXEMPLO PARA *E. precatoria*. (Bx, By) REPRESENTAM AS COORDENADAS X E Y DO CENTRO DA CAIXA DELIMITADORA; w REPRESENTA A LARGURA E h A ALTURA DA CAIXA DELIMITADORA.




FONTE: o autor (2025).

A FIGURA 19 ilustra um exemplo de imagem RGB utilizada no processo de detecção, acompanhada de sua respectiva anotação.

FIGURA 19 - CODIFICAÇÃO DO BANCO DE DADOS DE IMAGENS. CADA IMAGEM “.jpg” ESTÁ ACOMPANHADA DE UM ARQUIVO DE ANOTAÇÕES “.txt” NO FORMATO ADEQUANDO PARA YOLO.





FONTE: o autor (2025).

## 2.4 TREINAMENTO DO MODELO

Para o desenvolvimento dos modelos, foi utilizado o Jupyter Notebook em uma máquina local equipada com uma GPU NVIDIA 4090 com 40 GB de memória e 256 GB de RAM, proporcionando alta capacidade de processamento e eficiência para tarefas intensivas em computação. O Jupyter Notebook é uma ferramenta popular para pesquisa, ensino e desenvolvimento em aprendizado de máquina, permitindo a execução interativa de código Python. O treinamento foi realizado utilizando o modelo YOLOv10x, implementado na estrutura de aprendizado profundo PyTorch, sendo um *framework* de código aberto amplamente utilizado em aprendizado de máquina e visão computacional, conhecido por sua flexibilidade, facilidade de uso e integração com GPUs de alto desempenho.

O treinamento do modelo foi realizado com a arquitetura YOLOv10x, utilizando pesos pré-treinados e configurações definidas no arquivo “yolov10x.yaml”, com os dados organizados em cinco subdivisões (*folds*), conforme os arquivos “dataset/data\_foldX.yaml” (sendo X variando de 1 a 3). Os experimentos seguiram uma abordagem de validação cruzada, em que o modelo foi treinado e avaliado separadamente em cada *fold*. O processo de treinamento seguiu um conjunto de parâmetros específicos, incluindo definições de otimização, estratégias de *data augmentation* e ajustes estruturais do modelo, todos detalhados na TABELA 3. Essa configuração foi pensada para garantir a melhor performance possível do modelo, equilibrando capacidade de generalização, tempo de treinamento e fidelidade na detecção das classes-alvo.

TABELA 3 - CONFIGURAÇÃO DE TREINAMENTO PARA O MODELO YOLOV10X PARA O PERÍODO SECO E CHUVOSO (EXEMPLO PARA *FOLD1*).

| Parâmetro           | Valor                          |
|---------------------|--------------------------------|
| <i>task</i>         | <i>detect</i>                  |
| <i>mode</i>         | <i>Train</i>                   |
| <i>model</i>        | <i>yolov10x.yaml</i>           |
| <i>data</i>         | <i>dataset/data_fold1.yaml</i> |
| <i>epochs</i>       | <i>100</i>                     |
| <i>batch</i>        | <i>8</i>                       |
| <i>imgsz</i>        | <i>640</i>                     |
| <i>optimizer</i>    | <i>AdamW</i>                   |
| <i>lr0</i>          | <i>0.001</i>                   |
| <i>pretrained</i>   | <i>True</i>                    |
| <i>overlap_mask</i> | <i>True</i>                    |
| <i>mask_ratio</i>   | <i>4</i>                       |
| <i>augment</i>      | <i>False</i>                   |
| <i>mosaic</i>       | <i>1.0</i>                     |
| <i>mixup</i>        | <i>0.0</i>                     |
| <i>auto_augment</i> | <i>Randaugment</i>             |
| <i>erasing</i>      | <i>0.4</i>                     |
| <i>val</i>          | <i>True</i>                    |
| <i>iou</i>          | <i>0.7</i>                     |
| <i>max_det</i>      | <i>300</i>                     |
| <i>simplify</i>     | <i>True</i>                    |

*task*: define a tarefa como detecção de objetos (*detect*); *mode*: especifica que o modo de execução é o treinamento (*Train*); *model*: indica o arquivo de configuração da arquitetura YOLOv10x (*yolov10x.yaml*); *data*: aponta para o arquivo .yaml que organiza o conjunto de dados, classes e anotações (*data\_fold1.yaml*); *epochs*: número total de épocas de treinamento (100); *batch*: tamanho do lote (*batch size*), ou seja, número de imagens processadas por iteração (8); *imgsz*: tamanho das imagens de entrada, redimensionadas para 640×640 pixels, pelo método de interpolação bilinear; *optimizer*: algoritmo de otimização utilizado, sendo o *AdamW*, que favorece regularização e estabilidade; *lr0*: taxa de aprendizado inicial, aqui definida como 0.001; *pretrained*: uso de pesos pré-treinados (*True*), o que acelera a convergência e melhora a generalização; *overlap\_mask*: ativa o uso de máscaras com sobreposição para lidar com objetos adjacentes; *mask\_ratio*: define a intensidade ou proporção de aplicação das máscaras (4); *augment*: indica que aumentos adicionais de dados estão desativadas (*False*); *mosaic*: técnica de aumento de dados que mescla imagens, com valor 1.0 indicando uso completo; *mixup*: técnica de regularização baseada na mistura de imagens, desativada (0.0); *auto\_augment*: ativa o *Randaugment*, que aplica transformações aleatórias controladas; *erasing*: probabilidade de aplicar *random erasing* (apagamento aleatório), simulando oclusões (0.4 ou 40%); *val*: ativa a validação ao final de cada época de treinamento (*True*); *iou*: limiar de IoU mínimo para considerar uma detecção correta durante a avaliação (0.7); *max\_det*: número máximo de detecções por imagem (300); *simplify*: aplica simplificações estruturais no modelo para acelerar o treinamento (*True*).

## 2.5 MÉTRICAS E MÉTODOS DE AVALIAÇÃO

### 2.5.1 IoU (*Intersection over Union*)

O *IoU* é uma métrica amplamente utilizada em tarefas de detecção de objetos para avaliar a precisão das caixas delimitadoras (*bounding boxes*). Ele é calculado como a razão entre a área de interseção e a área de união das caixas predita e real. Em outras palavras, mede

a sobreposição entre a caixa prevista pelo modelo e a caixa verdadeira (*ground truth*). O valor de *IoU* varia de 0 a 1, onde 1 indica uma coincidência perfeita entre as caixas, e 0 indica que não há sobreposição. Utilizou-se um limiar de *IoU* 0,7 para determinar se uma detecção deve ser considerada verdadeira ( $IoU \geq 0,7$ ) ou falsa ( $IoU < 0,7$ ) (Equação 1).

$$IoU = \frac{\text{Área de sobreposição}}{\text{Área de união}} \quad (1)$$

### 2.5.2 Precisão (*Precision*)

A precisão é uma métrica que indica a proporção de detecções corretas (verdadeiros positivos, TP) em relação ao número total de detecções realizadas pelo modelo (TP + falsos positivos, FP). A precisão permite quantificar de todas as detecções realizadas pelo modelo, quantas estão corretas (Equação 2).

$$\text{Precisão}_i = \frac{TP}{TP + FP} \quad (2)$$

Uma alta precisão significa que o modelo cometeu poucas detecções incorretas, ou seja, realizou poucas previsões erradas de objetos inexistentes.

### 2.5.3 Sensibilidade (*Recall*)

O recall mede a capacidade do modelo de detectar objetos reais. Ele calcula a proporção de detecções corretas (TP) em relação ao número total de objetos reais (TP + falsos negativos, FN). O recall permite quantificar quantos foram detectados corretamente, de todos os objetos reais presentes na imagem (Equação 3).

$$\text{Recall}_i = \frac{TP}{TP + FN} \quad (3)$$

Um recall alto indica que o modelo consegue identificar a maioria dos objetos reais, minimizando o número de falsos negativos (FN).

### 2.5.4 *F1-Score*

O *F1-Score* é a média harmônica entre precisão e recall, proporcionando um equilíbrio entre ambas. Ele é especialmente útil quando se deseja alcançar um balanço entre a capacidade do modelo de detectar todos os objetos (recall) e a capacidade de evitar previsões incorretas (precisão). O *F1-Score* é particularmente relevante em casos onde tanto os FP quanto os FN têm impacto significativo (Equação 4).

$$F1\_score = 2 * \frac{precisão * Recall}{Precisão + Recall} \quad (4)$$

O *F1-Score* varia de 0 a 1, onde 1 representa o melhor desempenho possível, indicando que o modelo possui um bom equilíbrio entre precisão e recall.

#### 2.5.5 mAP (*Mean Average Precision*)

O mAP (*Mean Average Precision*) é uma métrica utilizada em tarefas de detecção de objetos para avaliar o desempenho geral de um modelo. Combina duas métricas importantes: precisão e recall, em diferentes limiares (*thresholds*), para gerar uma avaliação abrangente da qualidade das previsões do modelo em várias classes de objetos (Equação 5 e 6).

$$AP = \frac{1}{11} \sum_{r \in \{0; 0.1; 0.2; \dots; 0.9; 1\}} p_{interp}(r) \quad (5)$$

$$p_{interp}(r) = \max_{r' \geq r} (p(r')) \quad (6)$$

Em que,  $p_{interp}(r)$  é a precisão interpolada para um valor de recall  $r$ ;  $r' \geq r$  considera todos os pontos de recall maiores ou iguais ao valor atual  $r$ ;  $p(r')$  é o valor da precisão original nesse ponto  $r'$ ;  $\max_{r' \geq r} (p(r'))$  escolhe o maior valor de precisão entre todos os pontos a partir de  $r$ . O mAP é calculado como a média da *Average Precision* (AP) para cada classe do modelo. Ou seja, AP é a média ponderada das precisões em diferentes níveis de recall.

#### 2.5.6 Validação Cruzada *k-Fold*

A Validação Cruzada *k-Fold* é uma técnica utilizada para avaliar o desempenho de um modelo de aprendizado de máquina de forma robusta e confiável. O processo envolve dividir o conjunto de dados em  $k$  partes iguais (*folds*). O modelo é treinado  $k$  vezes, onde em cada iteração  $k-1$  *folds* são utilizados para treinamento e o *fold* restante para teste. Após as  $k$  iterações, o desempenho final do modelo é calculado como a média dos resultados de todos os *folds*, proporcionando uma estimativa mais geral e menos dependente de uma única divisão dos dados. Essa técnica evita problemas como *overfitting* e *underfitting* e é especialmente útil em cenários com poucos dados disponíveis.

#### 2.5.7 Pontuação de Confiança (*Confidence Score*) e Incerteza

A pontuação de confiança é uma métrica que indica o grau de confiança do modelo em suas previsões, variando entre 0 e 1, onde valores próximos a 1 indicam alta confiança. Em modelos de detecção de objetos, como o YOLO, a pontuação de confiança ajuda a filtrar detecções de baixa confiança. A incerteza, por outro lado, reflete o nível de dúvida do modelo



em relação a uma previsão. A relação entre pontuação de confiança e incerteza é inversa: quanto maior a incerteza, menor será a confiança do modelo na previsão.

### 3 RESULTADOS

Neste estudo, foram usadas 26.713 imagens para aplicar o modelo YOLOv10x utilizando a abordagem de validação cruzada ( $k=3$ ). A avaliação do modelo foi realizada em sete regiões distintas e, adicionalmente, considerando todas as regiões combinadas. O tempo médio de treinamento foi de 2,6 horas a cada 100 iterações, considerando as sete regiões e de 13,8 horas ao considerar todas as regiões agrupadas. Os tempos de treinamento e validação são apresentados na TABELA 4.


TABELA 4 - TEMPO MÉDIO DE TREINAMENTO E VALIDAÇÃO PARA AS SETE REGIÕES E PARA AS REGIÕES AGRUPADAS.

| Treinamento (h) |        |       |       |        | Validação (ms)*   |            |                   |
|-----------------|--------|-------|-------|--------|-------------------|------------|-------------------|
| Região          | fold1  | fold2 | fold3 | Média  | Pré-processamento | Inferência | Pré-processamento |
| Alto Acre       | 6,188  | 2,261 | 2,181 | 3,543  | 0,4               | 7,0        | 0,2               |
| Baixo Acre      | 4,233  | 4,681 | 3,837 | 4,250  | 0,1               | 7,3        | 0,2               |
| Juruá           | 0,866  | 0,934 | 0,932 | 0,911  | 0,2               | 8,2        | 0,2               |
| Rondônia        | 2,874  | 2,932 | 2,864 | 2,890  | 0,1               | 7,2        | 0,2               |
| Roraima         | 3,02   | 3,064 | 3,116 | 3,067  | 0,1               | 7,4        | 0,2               |
| Sul do Amazonas | 1,74   | 1,814 | 1,811 | 1,788  | 0,1               | 7,4        | 0,2               |
| Tarauacá Envira | 1,813  | 1,787 | 1,779 | 1,793  | 0,1               | 7,4        | 0,2               |
| Global          | 18,554 | 11,43 | 11,47 | 13,818 | 0,3               | 6,9        | 0,2               |

\* O tempo para inferência é dado por imagem e na unidade de milissegundos (ms).

A FIGURA 20 apresenta as curvas de aprendizado do modelo YOLOv10x ao longo das 100 iterações, considerando a média dos três treinamentos ( $k=3$ ) da validação cruzada, tanto para cada uma das sete regiões avaliadas quanto para o conjunto global de dados.

FIGURA 20 - CURVAS DE APRENDIZADO OBTIDAS POR MEIO DE VALIDAÇÃO CRUZADA (k=3) AO LONGO DE 100 ITERAÇÕES, DEMONSTRANDO A EVOLUÇÃO DO MAP PARA CADA UMA DAS SETE REGIÕES AVALIADAS E PARA O CONJUNTO GLOBAL DE DADOS.



FONTE: o autor (2025).

Os resultados da Média de Precisão (mAP) para a detecção das 14 espécies de palmeiras em cada região e para geral são apresentados na TABELA 5. As regiões do Baixo Acre, Roraima e Rondônia se destacaram pelo maior número de imagens e indivíduos observados, com 2767 imagens e 5.675 indivíduos no Baixo Acre, com 1.260 imagens e 4.676 indivíduos em Roraima, e 1.213 imagens e 2670 indivíduos em Rondônia (Conjunto de dados de validação). As demais regiões, como o Alto Acre e o Sul do Amazonas, apresentaram números mais baixos, com destaque para o Juruá, que registrou o menor número de imagens e indivíduos, com 330 e 694, respectivamente. Em termos e precisão da detecção, Rondônia e Roraima também apresentaram os maiores valores de mAP, que variam de 72% a 94 %, indicando alta precisão na detecção das espécies. Em contrapartida, o Juruá e Sul do Amazonas mostraram valores mais baixos, especialmente para algumas espécies, como a região Juruá, onde o mAP para a espécie “aa14” foi de 45%, e no Sul do Amazonas, com um mAP de 39% para a mesma espécie.

Além disso, a TABELA 5 apresenta os resultados obtidos a partir da matriz de confusão, calculada com base em uma amostra do conjunto de teste cobrindo aproximadamente 61 hectares da área de estudo e limiar de confiança para detecção de 0,25 (*threshold* = 0,25). As métricas de precisão, recall e F1-score foram computadas

individualmente por classe, permitindo avaliar o desempenho do modelo na identificação de diferentes espécies de palmeiras. A precisão média para todas as classes foi de 91%, o que indica que, entre as palmeiras que o modelo detectou, 91% das detecções foram corretas (verdadeiros positivos). Já a média para o recall foi de 76%, demonstrando que o modelo conseguiu identificar 76% das palmeiras realmente presentes na amostra analisada.

Em termos de desempenho por espécie, observa-se que algumas classes atingiram 100% de precisão e recall, refletindo uma alta confiabilidade nas predições dessas espécies. No entanto, outras apresentaram valores de recall mais baixos, como o caso do murumuru (au13) com apenas 16,67% de recall, o que sugere dificuldade do modelo em detectar todas as ocorrências dessa espécie no campo. O *F1-score*, que representa o equilíbrio entre precisão e recall, reforça essa variação entre classes: enquanto algumas espécies atingiram valores acima de 95%, outras ficaram abaixo de 30%, indicando a necessidade de melhorias específicas, como redução do limiar de confiança para um valor menos rigoroso.





A análise global do conjunto de dados revelou um valor de mAP de 79%, evidenciando um avanço expressivo na precisão da detecção. Esse desempenho pode ser atribuído à maior disponibilidade de dados para o treinamento e validação do modelo. Observou-se uma tendência clara: regiões com maior número de imagens e indivíduos anotados apresentaram melhores resultados em termos de mAP. Baixo Acre, Roraima e Rondônia, por exemplo, que concentraram os maiores volumes de dados (2.767, 1.260 e 1.213 imagens, respectivamente), alcançaram os valores mais elevados de precisão, variando em 90%, 70% e 72%, respectivamente. Em contraste, regiões com menor quantidade de dados, como o Juruá e o Sul do Amazonas, apresentaram desempenho inferior (35% e 36%, respectivamente). Esses resultados reforçam a importância de conjuntos de dados robustos e representativos, capazes de capturar a variabilidade natural das espécies e ambientes, contribuindo significativamente para o aumento da capacidade de generalização e da eficácia dos modelos de detecção.

A análise dos resultados por espécie revela variações significativas nos valores de mAP entre regiões. A espécie tucumã (aa14), por exemplo, apresentou desempenho elevado em Baixo Acre (98%), Tarauacá-Envira (87%) e Alto Acre (85%), mas teve queda expressiva no Juruá (45%) e Sul do Amazonas (39%), indicando uma possível influência da quantidade de dados disponíveis. A espécie jaci (ab10) destacou-se em Baixo Acre (94%) e Tarauacá-Envira (78%), mas obteve valores mais modestos nas demais regiões. De forma semelhante, a espécie pataúá (ob70) teve alto desempenho em Rondônia (89%) e Roraima (90%), refletindo a abundância de exemplos nessas regiões. Por outro lado, espécies como açaí (ep01 e ep35) apresentaram desempenhos bastante variáveis, com mAPs oscilando entre 0,1 a 0,9 dependendo da região. A espécie murumuru (au13), embora presente em várias regiões, mostrou baixo desempenho geral, com destaque negativo no Juruá (7%). Além disso, é importante destacar que algumas espécies como jauari (aj82), babaçu (as48) e cocão (at34) ocorreram exclusivamente nas regiões de Roraima, Rondônia e Juruá, respectivamente. Sendo que a ausência dessas espécies nas demais regiões podem ser explicada por sua distribuição geográfica natural, que é restrita a áreas específicas da Amazônia. Em alguns casos, embora a espécie ocorra na região, o número de indivíduos encontrados durante a coleta de dados não foi suficiente para compor um conjunto de treinamento representativo, o que pode levar a não a adicionar ao conjunto de dados de treinamento.

## 4 DISCUSSÃO

### 4.1 TREINO E VALIDAÇÃO

Os resultados obtidos neste estudo (TABELA 5) reforçam evidências da literatura sobre a importância crítica do volume e da representatividade dos dados no desempenho de modelos de detecção baseados em aprendizado profundo. Em consonância com Cui et al. (2024), que demonstraram que o aumento da quantidade de dados de treinamento melhora consistentemente a performance de modelos de detecção em tarefas visuais diversas, observou-se que, no contexto específico da detecção de palmeiras, que as regiões com maior número de imagens e indivíduos, como Roraima e Rondônia, apresentaram os maiores valores de mAP (70% e 72%, respectivamente). Esse padrão indica que conjuntos de dados mais extensos e diversificados favorecem a aprendizagem de padrões complexos, especialmente em ambientes com alta heterogeneidade estrutural, como a floresta amazônica. Por outro lado, em regiões como o Juruá e o Sul do Amazonas, onde o número de imagens foi significativamente menor (330 e 717, respectivamente), o desempenho dos modelos foi consideravelmente inferior (mAP = 35% e 36%). Tais resultados sugerem que conjuntos reduzidos limitam a capacidade do modelo de generalizar características relevantes das espécies-alvo, corroborando a necessidade de estratégias de coleta mais amplas e balanceadas para fortalecer a robustez dos modelos de detecção em florestas tropicais.

Outro fator importante a ser considerado ao trabalhar com imagens obtidas por RPAs diz respeito às condições operacionais durante a aquisição dos dados. Não se trata apenas do desempenho intrínseco do modelo de detecção, mas também de variáveis externas que afetam diretamente a qualidade das imagens e, consequentemente, os resultados. Estudos como a aplicação do YOLO na detecção de plantas daninhas por UAVs, por exemplo, demonstraram que fatores como estabilidade do voo, qualidade do sensor da câmera e interferências ambientais como variações de iluminação, presença de sombras e movimentação da vegetação exercem influência significativa na acurácia do modelo (Alif et al., 2024). Esses aspectos são especialmente relevantes em ambientes naturais complexos, como florestas tropicais, onde a heterogeneidade estrutural e as condições atmosféricas instáveis podem comprometer a padronização e a precisão da detecção.

O treinamento de um modelo global resultou em desempenho notavelmente superior em comparação aos modelos regionais, tanto em termos de média geral quanto na precisão por espécie (TABELA 5). O mAP global alcançou 80%, ficando atrás apenas da Região de Baixo Acre. Ao analisar os resultados por espécies, todas as classes apresentaram

desempenho acima de 57%, sendo que a grande maioria superou a marca de 80%. Especificamente, espécies como *as48* (94%), *ap12* (90%), *se04* (86%), *aa14* (85%), *ab10* (80%), *ob19* (84%), *ob70* (87%) e *aj82* (87%) se destacaram, evidenciando a robustez do modelo quando exposto a dados variados e representativos das diferentes regiões amazônicas.

Esse desempenho elevado demonstra que o modelo global conseguiu capturar com eficiência os padrões morfológicos e estruturais das palmeiras, mesmo em meio a diferentes contextos ecológicos, densidades populacionais e condições de luz ou cobertura. A diversidade do conjunto de dados, correspondendo a 4.951 imagens e mais de 13 mil indivíduos (conjunto de dados de validação), foi determinante para essa performance, ampliando a capacidade do modelo de generalizar e responder com alta precisão a novas amostras, independentemente da região de origem.

Além disso, o fato de que nenhuma espécie ficou abaixo de 57% de mAP no modelo global mostra que, mesmo aquelas com menor representatividade ou maior complexidade de detecção, ainda assim foram reconhecidas de forma satisfatória. Isso reforça que o treinamento global não apenas melhora o desempenho médio, mas também reduz a disparidade entre espécies, favorecendo a equidade na detecção e promovendo resultados mais consistentes e confiáveis para uso em aplicações práticas, como monitoramento florestal, inventário de biodiversidade e manejo sustentável de espécies nativas.

Adicionalmente, do ponto de vista operacional, a utilização de um modelo global apresenta vantagens significativas em termos de escalabilidade e aplicabilidade em cenários reais. Essa abordagem possibilita o monitoramento automatizado de extensas áreas florestais sem a exigência de treinamentos regionais específicos, o que se mostra particularmente vantajoso em contextos com restrições logísticas, financeiras ou de infraestrutura, como é comum em iniciativas de monitoramento contínuo de biodiversidade em regiões remotas. Entretanto, a adoção de um modelo global não elimina a importância da coleta de dados em múltiplas regiões. Pelo contrário, a diversidade espacial no conjunto de treinamento é fundamental para garantir a robustez e a capacidade de generalização do modelo. Uma vez treinado, o modelo global pode ser aplicado de forma confiável em áreas ainda não mapeadas, desde que as espécies-alvo estejam presentes nesses locais. Assim, o modelo passa a funcionar como uma ferramenta preditiva eficaz, reduzindo custos operacionais e ampliando o alcance espacial do monitoramento com precisões satisfatórias.



## 4.2 TESTE


Utilizamos o melhor conjunto de pesos treinados com dados de todas as regiões para testar o modelo em um conjunto de imagens independentes, ou seja, não utilizadas durante o treinamento. Esse procedimento permitiu avaliar a capacidade de generalização do modelo global na detecção de indivíduos de palmeiras em áreas inéditas. Os resultados indicaram um desempenho geral satisfatório, com valores de mAP (*mean Average Precision*) relativamente altos e consistentes com os observados durante o treinamento. O mAP médio obtido no teste foi de 78%, variando de 56% a 95%, o que demonstra um elevado potencial de aplicação do modelo global para detecção de palmeiras entre diferentes regiões amazônicas. Comparando-se os valores obtidos no teste com os valores obtidos durante o treinamento, observa-se uma pequena redução no mAP de algumas classes, o que é esperado em processos de validação externa (teste), mas que em geral se manteve próximo aos valores observados em validações internas (treinamento), indicando que não houve *overfitting*, ou seja, o modelo não se ajustou excessivamente aos dados de treinamento e manteve bom desempenho nos dados de teste. Essa estabilidade nos resultados é especialmente relevante em tarefas de detecção aplicadas à vegetação, onde o *overfitting* pode ser agravado por fatores como o tamanho reduzido do conjunto de dados, a alta variabilidade das espécies e a presença de ruído nas imagens (Zhang et al., 2020, Ayhan et al., 2020). A utilização de validação cruzada e a ampla variabilidade dos dados de entrada contribuíram para reduzir o *overfitting*, o que pôde ser observado no bom desempenho do modelo durante o teste em áreas independentes.

## 4.3 MATRIZ DE CONFUSÃO

Os resultados apresentados na TABELA 5 e na FIGURA 21 evidenciam a relevância da escolha apropriada de um limiar de confiança (*confidence threshold*) em tarefas de inferência, pois ela impacta diretamente a precisão, a recall e o equilíbrio entre falsos positivos e negativos. O uso de limiares é prática consolidada na avaliação de modelos de detecção, permitindo filtrar predições pouco confiáveis e melhorar a qualidade final dos resultados. Essa abordagem tem sido amplamente discutida na literatura recente por sua contribuição à robustez e interpretabilidade dos modelos (Lee et al., 2022; Chowdhury et al., 2022; Putra & Wijayanto, 2023; Wibowo et al., 2022).

Para facilitar a interpretação dos erros e acertos nas detecções, a FIGURA 21 apresenta a matriz de confusão, discriminando os acertos por espécie (Verdadeiros Positivos na diagonal principal e Falsos Positivos nas demais), além dos casos em que o modelo confundiu os indivíduos com o plano de fundo (bgFP) da imagem, ou aquelas palmeiras que o modelo deixou de detectar (bgFN).

FIGURA 21 - MATRIZES DE CONFUSÃO PARA O MODELO GLOBAL APLICADO AO CONJUNTO DE TESTE. (a) CONSIDERA TODAS AS CLASSES, SEM RESTRIÇÃO GEOGRÁFICA, COM LIMAR DE CONFIANÇA (*CONFIDENCE THRESHOLD*) DE 0,01; (b) APLICA RESTRIÇÕES GEOGRÁFICAS, ASSUMINDO QUE DETERMINADAS ESPÉCIES NÃO OCORREM SIMULTANEAMENTE EM ALGUMAS REGIÕES, COM *CONFIDENCE THRESHOLD* DE 0,01; (c) CONSIDERA RESTRIÇÕES GEOGRÁFICAS E UTILIZA UM LIMAR DE CONFIANÇA MAIS RIGOROSO (0,25).



FONTE: o autor (2025).

A matriz de confusão apresentada na FIGURA 21 permite identificar com clareza os principais desafios enfrentados na aplicação prática do modelo de detecção de palmeiras. Ao utilizar um modelo global, treinado com dados de diferentes regiões da Amazônia, é fundamental considerar a realização de uma análise pós-inferência. Isso se deve ao fato de que nem todas as espécies de palmeiras ocorrem em todas as regiões, e características morfológicas semelhantes entre espécies de gêneros próximos podem aumentar a taxa de confusão. Assim, a localização geográfica torna-se uma variável crucial na interpretação dos resultados e na redução de erros de classificação.

Como exemplo, observa-se na FIGURA 21a uma confusão significativa entre as espécies inajá (*Attalea maripa*, am16) e urucuri (*Attalea phalerata*, ap12), ambas pertencentes ao gênero *Attalea*, o que evidencia a semelhança morfológica entre elas (FIGURA 22b e 22c). Situação semelhante ocorreu com as espécies jaci (*Attalea butyracea*, ab10) e babaçu (*Attalea speciosa*, as48), do gênero *Attalea*, que também apresentaram confusão mútua. Da mesma forma, ocorreu com o tucumã (*Astrocaryum aculeatum*, aa14) e jauari (*Astrocaryum jauari*, aj82), por serem do mesmo gênero, compartilham características morfológicas semelhantes (FIGURA 22k e FIGURA 22l), o que pode levar a erros de classificação ou confundimento entre elas (FIGURA 21 e 22). Embora o jauari apresente predominantemente um padrão de ocorrência em touceiras, isto é, múltiplos indivíduos agrupados que se originam a partir de uma mesma planta matriz, foram identificados casos de ocorrência isolada que se assemelham à morfologia típica do tucumã (FIGURA 21). Isso poderia justificar parte da confusão na classificação observados entre essas classes. Uma alternativa, seria realizar a demarcação das copas individuais de cada perfilho da touceira, permitindo que o modelo aprenda não apenas características da espécie agrupada, o que poderia contribuir para a redução da taxa de confundimento entre copas morfológicamente parecidas.

Considerando esses fatores, a FIGURA 21b apresenta um panorama dos resultados obtidos com a aplicação de restrições baseadas na geolocalização das palmeiras. Observa-se um ganho significativo na precisão da detecção de espécies que anteriormente apresentavam confusão mútua, com um aumento de 41 pontos percentuais para urucuri (ap12) e 11 pontos percentuais para babaçu (as48). Em Roraima, a alta densidade de indivíduos de inajá resultou no entrelaçamento das copas, fazendo com que perdessem sua forma estrelada característica. Além disso, a disposição das pinas nesses casos pode assemelhar-se à morfologia do urucuri, o que levou à confusão do modelo, que passou a classificar inajá como urucuri (FIGURA

22b). Esse viés foi mitigado com a separação das regiões, permitindo ao modelo considerar a distribuição geográfica das espécies e, conseqüentemente, reduzir os erros de classificação.

Outro fator importante a ser considerado é o conhecimento sobre a fenologia e a morfologia das espécies. Ao longo de seus ciclos de vida, as plantas podem apresentar variações morfológicas significativas, relacionadas a diferentes estágios de desenvolvimento, estratégias ecológicas e respostas a condições ambientais (Kahn, 1986; Henderson, 2000; Lorenzi et al., 2004). Essas variações influenciam diretamente a acurácia de modelos de detecção, especialmente na distinção entre indivíduos jovens, adultos ou afetados por estresse.

Além disso, distúrbios ambientais, como queimadas e eventos climáticos extremos, e distúrbios antrópicos, como desmatamento, manejo seletivo, abertura de trilhas e fragmentação do habitat, devem ser cuidadosamente considerados ao aplicar modelos de detecção em ambientes florestais. Esses elementos podem alterar significativamente a fisionomia da vegetação e a distribuição espacial das espécies, impactando diretamente a capacidade do modelo em generalizar seus aprendizados. Incorporar essas variáveis ao processo de modelagem é fundamental para garantir maior robustez, adaptabilidade e acurácia na detecção de espécies em diferentes contextos da paisagem amazônica. A FIGURA 22a ilustra bem essa situação: um número expressivo de indivíduos de inajá não foi detectado pelo modelo, especialmente em uma área afetada por incêndio florestal, o que resultou em uma taxa de falsos negativos (FN) de aproximadamente 48,1% dos indivíduos presentes na região. As copas danificadas pelo fogo apresentaram padrões visuais distintos dos dados presentes no treinamento, o que comprometeu a capacidade de detecção. Esse caso evidencia a relevância de incluir uma classe específica para representar indivíduos afetados por fogo, como forma de contornar esse tipo de limitação e melhorar o desempenho do modelo em áreas sujeitas a distúrbios.



FIGURA 22 - EXEMPLO DE DETECÇÕES COM YOLOV10X, PARA AS 14 ESPÉCIES DE PALMEIRAS DISTRIBUÍDAS NAS 7 REGIÕES DA ÁREA DE ESTUDO.



FONTE: o autor (2025).

#### 4.4 LIMITAÇÕES E TRABALHOS FUTUROS

Apesar dos resultados positivos alcançados nesta pesquisa, algumas limitações devem ser consideradas para o aprimoramento da abordagem proposta. A detecção de espécies com morfologia semelhante, como inajá e urucuri ou tucumã e jauari, ainda apresenta desafios, especialmente em regiões com elevada densidade de indivíduos ou sobreposição de copas. Além disso, a baixa representação de indivíduos jovens no conjunto de

treinamento compromete a acurácia nessas classes etárias, como observado no caso da bacaba. Tais dificuldades reforçam que, embora o modelo global tenha demonstrado boa capacidade de generalização, ele ainda é sensível à composição dos dados de entrada. Nesse sentido, a integração de variáveis ambientais, como dados altimétricos, poderia refinar a detecção ao permitir distinguir ambientes de várzea e terra firme, que influenciam diretamente a distribuição natural das espécies amazônicas.

Como caminhos para trabalhos futuros, destaca-se o potencial de integrar informações provenientes de sensoriamento remoto orbital, como imagens dos satélites ou dados hiperespectrais, com os resultados obtidos por RPAs. Essa fusão de escalas e fontes pode ampliar a cobertura espacial e temporal das análises, ao mesmo tempo em que ajuda a corrigir inconsistências em áreas com pouca representatividade no treinamento. Da mesma forma, o uso de modelos probabilísticos de ocorrência de espécies, baseados em registros botânicos ou em algoritmos de nicho ecológico, permitiria incorporar o contexto biogeográfico às detecções, filtrando previsões inconsistentes e reforçando a interpretação ecológica dos resultados. A integração com variáveis climáticas, como pluviosidade e sazonalidade, também aparece como um recurso relevante, sobretudo em estudos voltados à fenologia ou mudanças no padrão de distribuição das palmeiras.

A principal contribuição deste estudo foi demonstrar que é possível treinar um modelo global robusto, baseado em imagens RGB de alta resolução captadas por drones, capaz de detectar múltiplas espécies de palmeiras em diferentes contextos ecológicos da Amazônia com alta assertividade. A construção e aplicação deste modelo representam um avanço importante para o monitoramento automatizado da vegetação, superando limitações regionais e reduzindo a necessidade de treinos locais. A abordagem proposta alia eficiência técnica, escalabilidade e potencial de replicação, sendo aplicável a iniciativas de mapeamento, manejo florestal, inventários de biodiversidade e projetos de bioeconomia. Ao integrar detecção visual com informações ambientais e ecológicas, futuros aprimoramentos poderão ampliar ainda mais a precisão e a aplicabilidade do modelo, tornando-o uma ferramenta valiosa para a conservação e gestão sustentável de ecossistemas amazônicos.

## 5 CONCLUSÃO

Este estudo demonstrou o potencial do uso de redes neurais convolucionais, em especial o modelo YOLOv10x, para a detecção de palmeiras economicamente importantes na Amazônia, utilizando imagens de drones em diferentes regiões da floresta tropical. A aplicação da validação cruzada ( $k=3$ ) permitiu avaliar de forma robusta o desempenho do modelo em cenários regionais e globais, revelando variações significativas associadas à quantidade e à diversidade dos dados disponíveis por região.

Regiões com maior número de imagens e indivíduos, como Baixo Acre, apresentaram os melhores desempenhos ( $mAP > 0,90$ ), enquanto áreas com amostragem limitada, como Juruá e Sul do Amazonas, obtiveram  $mAP$ s abaixo de 0,37. Por outro lado, o modelo global treinado com dados agregados de todas as regiões alcançou desempenho superior, com  $mAP$  geral de 0,79 e valores acima de 0,86 para a maioria das espécies, destacando-se como uma estratégia mais eficaz para generalização e aplicação prática em escalas maiores.

Além da precisão elevada, o modelo global demonstrou vantagens operacionais em termos de escalabilidade, reduzindo a necessidade de treinamentos específicos por região. No entanto, a coleta de dados em múltiplos contextos ecológicos continuam sendo essenciais para garantir a robustez do modelo, especialmente em aplicações preditivas em áreas ainda não mapeadas.

Os resultados obtidos reforçam o papel das técnicas de *deep learning* aliadas ao sensoriamento remoto como ferramentas promissoras para o monitoramento florestal, contribuindo para o mapeamento da biodiversidade e o manejo sustentável de espécies nativas na Amazônia.

## CAPÍTULO II

### IMPACTO DAS VARIAÇÕES SAZONAIS NA DETECÇÃO DE PALMEIRAS NA AMAZÔNIA COM YOLOV10X EM IMAGENS RGB OBTIDAS POR DRONES

#### RESUMO

A detecção automatizada de espécies vegetais em florestas tropicais impõe desafios significativos devido à estrutura complexa do dossel, à variabilidade fenológica sazonal e às dificuldades logísticas de acesso, especialmente durante o período de chuva intensa. Este estudo avaliou o desempenho do modelo de *deep learning* YOLOv10x na identificação de 10 espécies de palmeiras amazônicas com relevância econômica, utilizando 11.320 imagens RGB obtidas por drones durante as estações seca e chuvosa no estado do Acre. Os modelos foram avaliados por validação cruzada ( $k=5$ ) e reamostragem *bootstrap* para comparar as métricas de desempenho entre os períodos. Os resultados indicaram desempenho geral ligeiramente superior no período chuvoso ( $mAP = 83\%$ ), mas com variações expressivas entre espécies. A classe ep35 (açaí (*Euterpe precatoria*) na fase produtiva) apresentou melhores resultados na estação seca, possivelmente devido à maior visibilidade fenológica dos cachos florais. Em contrapartida, espécies de sub-bosque, como murumuru (*Astrocaryum ulei*), tiveram desempenho reduzido, refletindo limitações de visibilidade em áreas sombreadas. A escolha do período de coleta envolve um *trade-off* entre a dificuldade de acesso na estação chuvosa e a perda de qualidade das imagens no período seco, causada por queda foliar, brilho excessivo, artefatos visuais e incidência de ventos que comprometem a detecção automática. O estudo evidencia a eficácia dos modelos YOLO para o monitoramento de palmeiras e reforça a importância de considerar fatores sazonais, ecológicos e operacionais no planejamento da coleta e na composição dos dados de treinamento, visando maior acurácia na detecção em florestas tropicais.

**Palavras-chave:** Detecção de palmeiras, *deep learning*, Floresta Amazônica, sazonalidade fenológica.



## ABSTRACT

Automated detection of plant species in tropical forests presents significant challenges due to the complex canopy structure, seasonal phenological variability, and logistical difficulties of access, especially during the rainy season. This study evaluated the performance of the deep learning model YOLOv10x in identifying 10 economically important Amazonian palm species, using 11,320 RGB images captured by drones during the dry and rainy seasons in the state of Acre, Brazil. The models were evaluated using 5-fold cross-validation and bootstrap resampling to compare performance metrics between seasons. Results indicated a slightly better overall performance during the rainy season (mAP = 83%), with substantial variation across species. The ep35 class (açaí (*Euterpe precatoria*) in the productive phase) showed better results in the dry season, likely due to greater phenological visibility of flowering clusters. In contrast, understory species such as *Astrocaryum ulei* had reduced performance, reflecting visibility limitations in shaded areas. Choosing the image acquisition period involves a trade-off between limited access during the rainy season and image quality loss during the dry season due to leaf fall, excessive glare, visual artifacts, and wind incidence, which can hinder automated detection. This study demonstrates the effectiveness of YOLO models for palm monitoring and highlights the importance of considering seasonal, ecological, and operational factors in survey planning and training data composition to improve detection accuracy in tropical forests.

**Keywords:** Palm detection, Deep learning, UAV imagery, Amazon rainforest, Phenological seasonality

## 1 INTRODUÇÃO

A Floresta Amazônica é a maior floresta tropical do mundo, abrigando uma imensa diversidade biológica e desempenhando papel crucial na regulação do clima global. Entre os recursos naturais da região, destacam-se as palmeiras, que possuem grande importância ecológica, econômica e cultural. Espécies como o açaí (*Euterpe precatoria*), o babaçu (*Attalea speciosa*) e o buriti (*Mauritia flexuosa*) são amplamente utilizadas por populações locais, contribuindo para a segurança alimentar, geração de renda e práticas tradicionais (Kahn & de Granville, 1992; Henderson et al., 1995). Além disso, as palmeiras desempenham funções ecológicas essenciais, como dispersão de sementes, oferta de frutos para a fauna e manutenção da estrutura florestal.

Diferentes estudos vêm sendo implementados para aprimorar a coleta de dados sobre as palmeiras amazônicas, especialmente com o avanço das geotecnologias. O uso de sensoriamento remoto, incluindo imagens de satélite e drones (UAVs), tem se mostrado uma ferramenta promissora para mapear a distribuição e monitorar o estado dessas espécies (Castro et al., 2021; Ferreira et al., 2020, Karasinski et al., 2021). No entanto, ainda há desafios significativos devido às características estruturais da própria floresta (Jirka et al., 2007, Moulatlet et al., 2017). A alta densidade do dossel, a heterogeneidade espacial das espécies e a variação na reflectância das folhas ao longo do ano impõem limitações à detecção precisa de palmeiras individuais, principalmente em áreas de floresta primária. Além disso, a fenologia das espécies influencia diretamente a qualidade e disponibilidade dos dados. Durante a estação seca, muitas árvores decíduas e semi-decíduas perdem parte de suas folhas, alterando a estrutura do dossel e a resposta espectral da floresta, o que pode afetar a classificação e segmentação de indivíduos em imagens aéreas (Huete et al., 2006, Aragão et al., 2007; Brando et al., 2010, Veras et al., 2024). Por outro lado, na estação chuvosa, a maior cobertura foliar e a umidade atmosférica intensificam a interferência da biomassa e reduzem a penetração de sensores ópticos, dificultando a extração de informações detalhadas. Esses fatores indicam que, embora o sensoriamento remoto tenha avançado na identificação e quantificação de palmeiras, ainda são necessárias abordagens metodológicas que considerem a sazonalidade e a complexidade estrutural da floresta para aprimorar a precisão desses levantamentos.

Diante desses desafios, torna-se fundamental avaliar como a sazonalidade influencia a eficiência dos métodos automatizados de detecção, especialmente aqueles baseados em inteligência artificial. Modelos de *deep learning*, como as redes YOLO (*You Only Look*


*Once*), têm sido amplamente utilizados para tarefas de detecção de objetos em imagens aéreas, apresentando bons resultados em ambientes complexos. No entanto, ainda são escassos os estudos que comparam o desempenho desses modelos entre diferentes períodos sazonais na Amazônia. Este estudo tem como objetivo investigar se há diferença significativa na detecção de palmeiras a partir de imagens de drones coletadas durante a estação seca e a estação chuvosa, utilizando o modelo YOLOv10x. A partir dessa análise, espera-se contribuir para o aprimoramento das estratégias de monitoramento automatizado da flora amazônica, considerando as variações fenológicas e estruturais ao longo do ano.

## 2 MATERIAIS E MÉTODOS

### 2.1 LOCALIZAÇÃO E CARACTERIZAÇÃO FÍSICA DA ÁREA DE ESTUDO

O estudo foi conduzido na Região Amazônica Ocidental, no Estado do Acre, na Mesorregião Vale do Acre, abrangendo as Regionais Baixo Acre e Alto Acre (FIGURA 23). Faz parte do projeto Geoflora (21149.000754/2022-79), que se dedica às geotecnologias aplicadas à automação florestal e espacialização dos estoques de carbono em áreas de floresta nativa na Amazônia Ocidental. O Geoflora é uma iniciativa da Empresa Brasileira de Pesquisa Agropecuária (Embrapa) Acre com apoio do Fundo JBS pela Amazônia (FJBSA). A sede da Embrapa Acre está localizada no município de Rio Branco, estado do Acre, especificamente no trecho Rio Branco – Porto Velho, RO, à margem direita da BR 364 - Km 14, com coordenadas geográficas de 10° 01' 22" S e 67° 40' 3" W.

FIGURA 23 - LOCALIZAÇÃO DA ÁREA DE ESTUDO. EM VERDE ÁREA OCUPADA POR FLORESTA, EM AMARELO ÁREA DE TRANSIÇÃO DE FLORESTA PARA CERRADO, NOS ESTADOS DA AMAZÔNIA LEGAL.




FONTE: o autor (2025).

O clima da região de estudo, conforme a classificação de *Köppen*, é do tipo Am, característico de clima tropical de monções, com um período seco anual de aproximadamente três meses nas regiões do Baixo Acre e Alto Acre (Alvares, 2013; Cunha e Duarte, 2005;



IBGE, 1997). A temperatura média anual é de 24,3 °C, e a precipitação média é de cerca de 1.950 mm (FIGURA 24). A estiagem é bem definida e geralmente ocorre entre os meses de junho a setembro. Durante esse período, a vegetação sofre severos estresses hídricos. Árvores adaptadas a longos períodos de umidade enfrentam dificuldades em manter seus processos fisiológicos, como a transpiração e a fotossíntese. Em resposta, muitas espécies reduzem sua atividade metabólica e antecipam a queda de folhas, em um fenômeno conhecido como desfolhamento sazonal. Essa adaptação não apenas altera a paisagem, mas também traz implicações ecológicas importantes, afetando o microclima local e a biodiversidade da região.

FIGURA 24 - PRECIPITAÇÃO MÉDIA MENSAL NOS ÚLTIMOS 10 ANOS PARA O VALE DO ACRE COM BASE NAS ESTAÇÕES METEOROLÓGICAS DE RIO BRANCO E EPITACIOLÂNDIA (INMET, 2025).



FONTE: o autor (2025).

## 2.2 DADOS

Os dados provenientes de RPA foram adquiridos entre os anos de 2022 e 2024, com resolução espacial de 4 cm por pixel, sendo organizados de acordo com os períodos seco e chuvoso. Com base na literatura e em consonância com a FIGURA 24, foram selecionadas imagens dos meses de junho, julho e agosto para compor o conjunto referente ao período seco. As demais imagens foram alocadas no conjunto do período chuvoso. Inicialmente, 10% do total de imagens de cada período foram separadas aleatoriamente para compor os conjuntos de teste, de modo a avaliar o desempenho final dos modelos de detecção. Com isso, o período seco ficou com 4.923 imagens para treinamento e 1.190 para validação, enquanto o

período chuvoso contou com 4.178 imagens para treinamento e 1.029 para validação. Os conjuntos de treinamento de cada período foram então submetidos à validação cruzada com 5 *folds*, permitindo uma avaliação mais robusta da generalização dos modelos. Essa abordagem possibilitou o treinamento e validação dos modelos em diferentes subdivisões dos dados, garantindo maior confiabilidade nos resultados.

## 2.3 PRÉ-PROCESSAMENTO E TREINAMENTO DOS DADOS

O processo de treinamento adotado neste capítulo seguiu a mesma metodologia descrita no capítulo anterior (Seções 2.3e 2.4), utilizando o modelo YOLOv10x implementado em PyTorch, com execução via Jupyter Notebook em ambiente local equipado com GPU NVIDIA 4090 (40 GB) e 256 GB de RAM. Foram mantidas as mesmas configurações de arquitetura e hiperparâmetros descritas na TABELA 3. Além disso, a etapa de anotação também seguiu a mesma abordagem utilizada no primeiro capítulo, com o pré-processamento padronizado das imagens e a demarcação manual das copas individuais das palmeiras. Dessa forma, assegurou-se a padronização entre os experimentos conduzidos nos diferentes períodos (seco e chuvoso), permitindo comparações robustas entre os modelos.

## 2.4 MÉTRICAS

Para avaliar o desempenho de modelos de detecção de objetos, especialmente em tarefas como a identificação de árvores em imagens, utilizamos métricas padronizadas que permitem quantificar a qualidade das predições. Na TABELA 6 estão elencadas as principais métricas utilizadas (Equações 1 a 5).

TABELA 6 - MÉTRICAS UTILIZADAS NA AVALIAÇÃO DO YOLOV10X PARA OS PERÍODOS SECOS E CHUVOSOS NO VALE DO ACRE.

| Métrica         | Fórmula                                                                       | Descrição                                                                           | Bibliografia                                   | Equação |
|-----------------|-------------------------------------------------------------------------------|-------------------------------------------------------------------------------------|------------------------------------------------|---------|
| <i>IoU</i>      | $IoU = \frac{\text{Área de sobreposição}}{\text{Área de união}}$              | Mede a sobreposição entre a predição e a caixa real.                                | Everingham et al., (2010)                      | (1)     |
| Precisão        | $Precisão_i = \frac{TP}{TP + FP}$                                             | Proporção de verdadeiros positivos entre todas as predições positivas feitas.       | Powers, D. M. W. (2011).                       | (2)     |
| <i>Recall</i>   | $Recall_i = \frac{TP}{TP + FN}$                                               | Proporção de verdadeiros positivos em relação ao total de objetos reais.            | Powers, D. M. W. (2011)                        | (3)     |
| <i>F1-Score</i> | $F1\_score = 2 * \frac{precisão * Recall}{Precisão + Recall}$                 | Média harmônica entre precisão e recall, útil em conjuntos de dados desbalanceados. | van Rijsbergen, C. J. (1979).                  | (4)     |
| mAP             | $AP = \frac{1}{11} \sum_{r \in \{0; 0.1; 0.2; \dots; 0.9; 1\}} p_{interp}(r)$ | Média das precisões médias (AP) em todas as classes.                                | Everingham et al., (2010) e Lin et al., (2014) | (5)     |

IoU= Área de Interseção sobre união (*Intersection over Union*), TP = Verdadeiro Positivo (*True Positive*), FP = Falso Positivo (*False Positive*), FN = Falso Negativo (*False Negative*).

## 2.5 COMPARAÇÃO ENTRE PERÍODOS SAZONAIS VIA VALIDAÇÃO CRUZADA E *BOOTSTRAP*

Para avaliar a robustez das métricas de desempenho do modelo YOLOv10x, foi adotado o método de validação cruzada estratificada com 5 *folds*. Para cada *fold*, foram obtidos os valores de Precisão, *Recall* e média da precisão média (mAP), totalizando cinco observações por métrica para cada classe. A partir dessas cinco observações por métrica, buscou-se estimar a incerteza associada aos resultados obtidos, especialmente considerando a comparação entre diferentes condições, como períodos sazonais (seca e chuvoso). Dado o número reduzido de repetições ( $n = 5$ ), adotou-se o método de *bootstrap* com reposição para construir intervalos de confiança empíricos de 95% para as métricas. Essa técnica permite a estimação não paramétrica da variabilidade, sem pressupor distribuição normal dos dados, sendo especialmente recomendada em cenários de amostragem limitada (Efron & Tibshirani, 1993; Braga-Neto & Dougherty, 2004).

Para cada métrica e cada classe, foram geradas 10.000 amostras *bootstrap* com reposição a partir dos valores observados nos *folds*. Em cada repetição, foi computada a média da métrica reamostrada, formando assim uma distribuição empírica de médias *bootstrap*. No caso das comparações entre grupos (seca vs. chuvoso), o procedimento foi

replicado separadamente para cada grupo. Seja  $\{x_1^{(s)}, \dots, x_5^{(s)}\}$  o conjunto de valores observados no grupo seco, e  $\{x_1^{(c)}, \dots, x_5^{(c)}\}$  no grupo chuvoso. Para cada iteração  $b \in \{1, \dots, B\}$ , com  $B=10.000$ , foram geradas amostras com reposição, e calculadas as médias *bootstrap* (Equação 6).

$$\bar{x}_b^{(s)} = \frac{1}{n} \sum_{i=1}^n x_{b,i}^{(s)}, \quad \bar{x}_b^{(c)} = \frac{1}{n} \sum_{i=1}^n x_{b,i}^{(c)} \quad (6)$$

No caso das comparações entre grupos (seco vs. chuvoso), o procedimento foi replicado separadamente para cada grupo, e a diferença entre as médias *bootstrap* foi computada em cada amostra pareada Equação 7.

$$d_b = \bar{x}_b^{(s)} - \bar{x}_b^{(c)} \quad (7)$$

A partir da distribuição das diferenças médias  $\{d_1, \dots, d_B\}$ , foi então calculado o intervalo de confiança de 95%, utilizando os percentis 2,5% e 97,5% da distribuição amostrada (Equação 8).


$$IC_{95\%} = [P_{2,5}(d), P_{97,5}(d)] \quad (8)$$

Considerou-se que há diferença estatisticamente significativa entre os períodos seco e chuvoso quando o intervalo de confiança de 95% da diferença média, obtido por *bootstrap* pareado, não inclui o valor zero. Essa condição equivale à rejeição da hipótese nula ( $H_0$ ), que assume não haver diferença real entre os grupos, a um nível de significância de 5%. A ausência do zero no intervalo indica que a diferença observada entre os períodos é robusta o suficiente para não ser atribuída ao acaso, representando uma separação consistente entre as distribuições amostrais (Witten et al., 2011; Efron & Tibshirani, 1993).

### 3 RESULTADOS

Neste estudo, foram utilizadas 11.320 imagens obtidas por RPA entre os anos de 2022 e 2024, organizadas de acordo com os períodos seco (6.113 imagens) e chuvoso (5.207 imagens). Os conjuntos de treinamento de cada período foram submetidos à validação cruzada estratificada com 5 *folds*, permitindo uma avaliação mais robusta da capacidade de generalização dos modelos YOLOv10x em diferentes condições sazonais. Essa abordagem garantiu que cada imagem fosse utilizada tanto para treinamento quanto para validação, promovendo maior confiabilidade nos resultados. A evolução do desempenho dos modelos ao longo das iterações pode ser visualizada na curva de aprendizagem apresentada na FIGURA 25.

FIGURA 25 - CURVA DE APRENDIZAGEM PARA OS PERÍODOS SECO E CHUVOSO, COM A MÉDIA DOS CINCO *FOLDS*. AS CURVAS INDIVIDUAIS, EXIBIDAS AO FUNDO COM MENOR OPACIDADE, ILUSTRAM A VARIAÇÃO ENTRE OS *FOLDS*.



FONTE: o autor (2025).

Os resultados da aprendizagem dos modelos treinados com dados dos períodos seco e chuvoso são apresentados na TABELA 7, incluindo métricas de desempenho por espécie. De modo geral, observa-se um desempenho superior dos modelos treinados no período chuvoso, com destaque para os valores de mAP e F1-score, que atingiram 0,8288 e 0,7692 nos dados chuvosos, respectivamente, em comparação a 0,8052 e 0,7393 no período seco. Apesar dessa tendência global, é fundamental analisar o desempenho por espécie



individualmente, uma vez que algumas apresentaram variações específicas que não seguem o padrão geral, refletindo possíveis diferenças morfológicas, fenológicas ou de visibilidade nas imagens.


TABELA 7 - RESULTADOS DA APRENDIZAGEM DO MODELO CONSIDERANDO AS ESTAÇÕES SECAS E CHUVOSAS.

| Espécie |            |        |        |        |        |        |        |        |        |        |        |        |
|---------|------------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| Período | Todas      | aa14   | ab10   | am16   | ap12   | aul3   | ep01   | ep35   | mf09   | ob19   | se04   |        |
| Chuvoso | Imagens    | 1041   | 84     | 104    | 39     | 56     | 39     | 256    | 108    | 19     | 251    | 86     |
|         | Instâncias | 1965   | 102    | 165    | 45     | 94     | 59     | 327    | 169    | 89     | 624    | 291    |
|         | Precisão   | 0,7844 | 0,8304 | 0,8096 | 0,8272 | 0,8570 | 0,7980 | 0,7852 | 0,6998 | 0,6994 | 0,8234 | 0,7122 |
|         | Recall     | 0,7546 | 0,9092 | 0,7840 | 0,7404 | 0,7942 | 0,6054 | 0,8300 | 0,5580 | 0,7498 | 0,8712 | 0,7028 |
|         | mAP        | 0,8288 | 0,9388 | 0,8680 | 0,8380 | 0,8962 | 0,7202 | 0,8786 | 0,6784 | 0,7836 | 0,9220 | 0,7662 |
|         | F1-Score   | 0,7692 | 0,8680 | 0,7966 | 0,7814 | 0,8244 | 0,6885 | 0,8070 | 0,6209 | 0,7237 | 0,8466 | 0,7075 |
| Seco    | Imagens    | 1223   | 60     | 110    | 41     | 71     | 68     | 265    | 94     | 238    | 93     | 183    |
|         | Instâncias | 2962   | 69     | 231    | 50     | 126    | 131    | 467    | 136    | 1088   | 200    | 463    |
|         | Precisão   | 0,7598 | 0,7776 | 0,7656 | 0,6794 | 0,8068 | 0,7172 | 0,7336 | 0,8170 | 0,7362 | 0,7782 | 0,7866 |
|         | Recall     | 0,7198 | 0,7374 | 0,7382 | 0,7000 | 0,7464 | 0,5490 | 0,6296 | 0,8256 | 0,7744 | 0,6930 | 0,8030 |
|         | mAP        | 0,8052 | 0,8318 | 0,8266 | 0,7280 | 0,8204 | 0,6942 | 0,7614 | 0,8886 | 0,8204 | 0,8114 | 0,8696 |
|         | F1-Score   | 0,7393 | 0,7570 | 0,7517 | 0,6895 | 0,7754 | 0,6219 | 0,6776 | 0,8213 | 0,7548 | 0,7331 | 0,7947 |

As amplitudes das métricas entre as espécies também revelam diferenças relevantes. No período chuvoso, o valor de mAP50 variou de 68% (ep35) a 94% (aa14), enquanto no seco, os valores oscilaram de 70% (aul3) a 89% (ep35). Essa variação mostra que algumas espécies, como aa14, ob19 e ab10, mantêm desempenhos elevados independentemente da estação, enquanto outras, como ep35 e au13, demonstram maior sensibilidade à sazonalidade.

As diferenças de desempenho entre os períodos seco e chuvoso foram analisadas estatisticamente por meio do método de *bootstrap* pareado com 10.000 reamostragens, considerando os valores de Precisão, *Recall* e mAP para cada espécie. Essa abordagem permitiu estimar a incerteza associada às diferenças médias observadas, bem como gerar intervalos de confiança de 95% (TABELA 8). Os resultados de mAP revelaram que, embora o período chuvoso tenha apresentado tendência geral de desempenho superior, as diferenças entre os períodos não foram estatisticamente significativas para todas as espécies. Em alguns casos, como açaí produtivo (ep35) e paxiuba (se04), foram observadas diferenças positivas significativas em favor do período seco, com intervalos de confiança que não incluíam o zero (TABELA 8). Por outro lado, espécies como jací (ab10), murumuru (au13) e buriti (mf09) apresentaram diferenças não significativas, indicando desempenho semelhante entre os períodos. Esses resultados reforçam que o efeito da sazonalidade pode ser específico por espécie, e que a variabilidade intraespécie deve ser considerada na interpretação do desempenho dos modelos (FIGURA 26).

FIGURA 26 - DISTRIBUIÇÃO DAS DIFERENÇAS DE DESEMPENHO (PRECISÃO, RECALL E MAP) ENTRE OS PERÍODOS SECO E CHUVOSO POR ESPÉCIE, OBTIDA POR BOOTSTRAP PAREADO COM 10.000 REAMOSTRAGENS. CADA *BOXPLOT* REPRESENTA A DISTRIBUIÇÃO DAS DIFERENÇAS AMOSTRADAS (SECO – CHUVOSO), PERMITINDO VISUALIZAR A DIREÇÃO E A MAGNITUDE DA DIFERENÇA PARA CADA ESPÉCIE. VALORES ACIMA DE ZERO INDICAM MELHOR DESEMPENHO NO PERÍODO SECO; ABAIXO, NO CHUVOSO.



FONTE: o autor (2025).

A TABELA 8 apresenta as diferenças médias entre os períodos seco e chuvoso para cada espécie e métrica de desempenho, acompanhadas de seus respectivos intervalos de confiança de 95%, obtidos por meio de *bootstrap* pareado com reposição. Esse procedimento estatístico foi utilizado para estimar a variabilidade das diferenças entre os períodos, permitindo identificar os casos em que houve significância estatística. Diferenças foram

consideradas significativas quando o intervalo de confiança não incluiu o valor zero, indicando rejeição da hipótese nula de igualdade entre os desempenhos sazonais.

TABELA 8 - DIFERENÇA MÉDIA ENTRE OS PERÍODOS SECO E CHUVOSO POR ESPÉCIE E MÉTRICA, COM INTERVALO DE CONFIANÇA DE 95% (*BOOTSTRAP* PAREADO)

| Métrica  | Classe | Diferença entre períodos (Seco - Chuvoso) [IC95%] |
|----------|--------|---------------------------------------------------|
| Precisão | aa14   | -0,053 [-0,116, 0,015] ns                         |
|          | ab10   | -0,044 [-0,131, 0,035] ns                         |
|          | am16   | -0,148 [-0,187, -0,114] *                         |
|          | ap12   | -0,05 [-0,085, -0,012] *                          |
|          | au13   | -0,081 [-0,154, -0,007] *                         |
|          | ep01   | -0,052 [-0,103, -0,004] *                         |
|          | ep35   | 0,117 [0,039, 0,179] *                            |
|          | mf09   | 0,037 [-0,014, 0,087] ns                          |
|          | ob19   | -0,045 [-0,076, -0,002] *                         |
|          | se04   | 0,074 [0,024, 0,125] *                            |
| Recall   | aa14   | -0,172 [-0,215, -0,127] *                         |
|          | ab10   | -0,046 [-0,093, 0,01] ns                          |
|          | am16   | -0,04 [-0,079, 0,012] ns                          |
|          | ap12   | -0,048 [-0,099, 0,003] ns                         |
|          | au13   | -0,056 [-0,119, 0,007] ns                         |
|          | ep01   | -0,2 [-0,267, -0,134] *                           |
|          | ep35   | 0,268 [0,213, 0,33] *                             |
|          | mf09   | 0,025 [-0,028, 0,082] ns                          |
|          | ob19   | -0,178 [-0,232, -0,144] *                         |
|          | se04   | 0,1 [0,026, 0,166] *                              |
| mAP      | aa14   | -0,107 [-0,147, -0,072] *                         |
|          | ab10   | -0,041 [-0,073, 0,01] ns                          |
|          | am16   | -0,11 [-0,163, -0,046] *                          |
|          | ap12   | -0,076 [-0,113, -0,042] *                         |
|          | au13   | -0,026 [-0,059, 0,008] ns                         |
|          | ep01   | -0,117 [-0,142, -0,089] *                         |
|          | ep35   | 0,21 [0,146, 0,255] *                             |
|          | mf09   | 0,037 [-0,001, 0,074] ns                          |
|          | ob19   | -0,111 [-0,124, -0,095] *                         |
|          | se04   | 0,103 [0,05, 0,157] ns                            |

\* = diferença estatisticamente significativa (IC95% não inclui zero), ns = não significativa (IC95% inclui zero). Valores positivos indicam maior desempenho no período seco, enquanto valores negativos indicam melhor desempenho no período chuvoso. A interpretação deve considerar tanto o valor da diferença quanto seu intervalo de confiança.

Embora os *boxplots* ilustrados na FIGURA 26 apresentem, em alguns casos, caudas que cruzam o valor zero, a avaliação da significância estatística foi conduzida com base nos intervalos de confiança (IC) gerados por meio de *bootstrap* pareado (TABELA 8). Os gráficos mostram a distribuição empírica das médias *bootstrap* e são úteis para visualizar a dispersão das estimativas, incluindo *outliers*. No entanto, eles não devem ser utilizados como critério para inferência estatística. A significância das diferenças entre os períodos seco e chuvoso foi determinada com base nos ICs de 95% obtidos a partir das médias reamostradas e considerou-

se estatisticamente significativa toda diferença cujo intervalo de confiança não incluiu o valor zero (TABELA 8). Dessa forma, mesmo quando o *boxplot* aparenta cruzar o zero, a interpretação rigorosa deve se apoiar nos limites percentílicos calculados ( $p = 2,5\%$  e  $p = 97,5\%$ ), que oferecem uma estimativa robusta da incerteza associada às médias observadas.



#### 4 DISCUSSÃO


Ao analisarmos as métricas de *recall* e *precisão*, é possível observar um panorama interessante do desempenho do modelo no reconhecimento das diferentes espécies de palmeiras em ambas as estações. De maneira geral, o modelo demonstra um bom equilíbrio entre identificar a maioria das instâncias das espécies (*recall*) e minimizar os falsos positivos (*precisão*), como indicado pelos valores na coluna 'Todas'. No entanto, ao desagregar os resultados por espécie, nota-se variações significativas (TABELA 8 e FIGURA 26). Algumas espécies, como ep01 e se04, apresentam um *recall* elevado (83% e 87%, respectivamente), sugerindo que o modelo é eficaz em detectar a maioria das ocorrências dessa espécie, mesmo que isso implique em alguns falsos positivos. Por outro lado, algumas espécies apresentaram valores mais elevados de *precisão*, o que indica que, quando o modelo as identifica, geralmente está correto. No entanto, essa elevada especificidade pode vir acompanhada de um baixo *recall*, revelando uma limitação na capacidade de detecção completa dos indivíduos presentes. Em termos ecológicos, isso significa que o modelo pode omitir uma parcela significativa da população real, levando à subestimação do estoque populacional e, por consequência, a decisões equivocadas no planejamento de ações de manejo, conservação ou uso sustentável. Um exemplo marcante é o caso do murumuru (au13), que apresentou os menores valores de *recall* tanto na estação chuvosa (0,6054) quanto, de forma ainda mais acentuada, na seca (0,5490). Essa limitação pode estar associada a características ecológicas intrínsecas da espécie, como sua ocorrência preferencial nos estratos inferiores da floresta (Pesque *et al.*, 2009), onde as copas são frequentemente obstruídas por espécies emergentes, reduzindo a visibilidade nas imagens aéreas RGB. A presença de sombras, sobreposição de copas e menor contraste com o fundo são fatores que podem dificultar ainda mais a detecção.

Embora a sazonalidade da floresta não afete diretamente a fenologia da maioria das palmeiras analisadas neste estudo, os resultados indicam que o período de aquisição das imagens por RPA pode influenciar significativamente a *precisão* e a eficácia na detecção dessas espécies (FIGURA 26). Frequentemente, a escolha do momento de coleta é determinada por fatores logísticos, como a acessibilidade às áreas de interesse e a necessidade de reduzir os riscos operacionais durante a coleta, principalmente na estação chuvosa. No entanto, apesar da maior facilidade de acesso no período seco, esse período pode implicar em desafios adicionais. Durante a seca, por uma questão adaptativa ao estresse hídrico, é comum a queda foliar de algumas espécies, o que resulta em menor cobertura foliar do dossel e maior incidência de radiação solar, criando condições propícias à formação de copas esbranquiçadas, brilho excessivo e artefatos de saturação nas imagens RGB (FIGURA 28).

Essas alterações comprometem a qualidade visual das imagens, dificultando a detecção automática e aumentando a probabilidade de o modelo confundir copas-alvo com clareiras, troncos ou galhos expostos.

Outro fator ambiental que merece atenção no planejamento das aquisições das imagens por RPA é a incidência de ventos (FIGURA 27). Embora a velocidade média anual do vento na região seja relativamente baixa, com valores geralmente inferiores a 2,0 m/s, estudos apontam que, nos meses de junho a agosto, há maior predominância de ventos oriundos dos quadrantes sul, sudeste e leste, com possibilidade de ocorrência de rajadas que podem ultrapassar os 20 m/s (Duarte, 2006, Sousa, 2019; INMET, 2025). Essas condições, ainda que esporádicas, são suficientes para induzir o movimento das copas durante o sobrevoo, dificultando a estabilidade das imagens obtidas e comprometendo o processo de ortorretificação. O balanço das copas pode gerar descontinuidades nos mosaicos, com falhas de alinhamento espacial que afetam negativamente a qualidade das ortofotos e, por consequência, a acurácia dos modelos de detecção. Portanto, mesmo que o período seco ofereça vantagens operacionais, como menor pluviosidade e melhor acesso às áreas remotas, a maior frequência e intensidade dos ventos deve ser considerada na escolha das janelas de voo, visando a obtenção de imagens com maior estabilidade e fidelidade estrutural do dossel florestal.

FIGURA 27 – DISTRIBUIÇÃO MENSAL DA FREQUÊNCIA E INTENSIDADE DOS VENTOS POR DIREÇÃO (INMET, 2025). AS CORES INDICAM FAIXAS DE VELOCIDADE (m/s), E O TAMANHO DOS SETORES REPRESENTA A FREQUÊNCIA DOS VENTOS EM CADA DIREÇÃO.




FONTE: o autor (2025).

Diante desses desafios, torna-se fundamental o desenvolvimento de estratégias que conciliem as limitações logísticas com a manutenção da qualidade das imagens utilizadas para detecção. Uma abordagem promissora consiste na incorporação de dados multitemporais no processo de treinamento dos modelos, permitindo que o algoritmo aprenda a reconhecer padrões de copa sob diferentes condições sazonais e de iluminação. Além disso, técnicas de pré-processamento das imagens RGB, como realce de contraste ou remoção de brilho especular, poderiam contribuir significativamente para atenuar os efeitos adversos observados no período seco. Embora o YOLOv10x utilize estratégias de *data augmentation* para lidar com variações visuais, essas abordagens nem sempre compensam distorções sistemáticas presentes nas imagens originais. Uma abordagem promissora consiste na incorporação de dados multitemporais no treinamento dos modelos, permitindo que o algoritmo aprenda a reconhecer padrões de copa sob diferentes condições sazonais e de iluminação. Essa estratégia

tem sido defendida em estudos recentes na Amazônia, como o de Veras et al. (2023), que demonstraram o potencial do uso de imagens RGB obtidas por RPA para estimar atributos dendrométricos com elevada acurácia, mesmo em florestas tropicais de alta complexidade estrutural. Figueiredo et al. (2025) demonstram que as espécies arbóreas sofrem alterações morfológicas significativas no período seco, comprometendo o reconhecimento visual e automatizado das copas, ao passo que as palmeiras mantêm padrões morfológicos mais estáveis ao longo do ano, o que favorece sua detecção. No entanto, é importante destacar que mesmo variações sutis nas palmeiras podem impactar o desempenho dos modelos de detecção. Observou-se que, durante o período seco, as palmeiras tendem a manter folhas mais envelhecidas, com tonalidade menos vibrante, enquanto no período chuvoso predominam folhas jovens, o que pode alterar a resposta espectral e os padrões morfológicos captados nas ortofotos. Essas diferenças, ainda que discretas, reforçam a importância da escolha criteriosa do momento de coleta das imagens para maximizar a acurácia dos algoritmos de inteligência artificial aplicados ao reconhecimento de copas. Assim, a definição do período de coleta das imagens não deve ser apenas uma decisão operacional, mas sim uma estratégia metodológica com impactos diretos na eficácia da detecção automatizada em florestas tropicais.



FIGURA 28 - COMPARAÇÃO DE IMAGENS NO PERÍODO SECO E CHUVOSO. (e) DESTAQUE PARA A PALMEIRA DE *Euterpe precatoria* Mart. SEM CACHO, (f) DESTAQUE PARA *Euterpe precatoria* Mart. COM CACHO.



FONTE: o autor (2025).

Um destaque relevante nos resultados foi a classe ep35, correspondente ao açai (*Euterpe precatoria* Mart.) na fase fenológica produtiva, que apresentou desempenho significativamente superior no período seco. Essa diferença pode ser atribuída a aspectos fenológicos característicos da espécie: durante a estação seca, é comum observar indivíduos em fase de florescimento ou início da formação dos cachos, o que confere um aspecto visual mais evidente nas imagens de RPA, com tonalidades claras e texturas contrastantes que evidenciam tais características. Em contrapartida, no período chuvoso, as imagens podem ter sido capturadas em estágios mais avançados, nos quais os frutos estão escurecidos ou já caíram, dificultando sua distinção visual em relação à vegetação ao redor. Essa diferença de



aparência entre os períodos é destacada na FIGURA 28e e FIGURA 28f, que exemplificam as condições visuais típicas da estação chuvosa e seca para a espécie, respectivamente. Essa dinâmica fenológica é coerente com registros que indicam o pico de frutificação de *E. precatoria* entre os meses de dezembro (Bovi & Castro, 1993, Teixeira et al., 2024). Vale destacar que a safra de *E. precatoria* varia consideravelmente conforme o ambiente e a localização geográfica. Em áreas de baixio no Acre, o pico de produção ocorre entre março e junho, enquanto em áreas de terra firme concentra-se entre julho e outubro (Bayma et al., 2008; Sebrae, 2014). Em Epitaciolândia, por exemplo, as plantas de baixio frutificam de março a junho, e as de terra firme de junho a outubro (Shanley & Medina, 2005). Essa variabilidade na fenologia regional e ambiental pode explicar diferenças intraespecíficas observadas nas imagens entre áreas e períodos, sugerindo que o contexto ecológico local deve ser considerado na interpretação da performance dos modelos de detecção.

## 5 CONCLUSÃO

Os resultados obtidos neste estudo demonstram o potencial da aplicação de modelos de detecção baseados em redes neurais convolucionais (YOLOv10x) para identificar automaticamente espécies de palmeiras em florestas tropicais utilizando imagens RGB adquiridas por RPA. A análise comparativa entre os períodos seco e chuvoso evidenciou uma tendência geral de melhor desempenho nos dados de períodos chuvosos, especialmente nas métricas mAP e F1-score. No entanto, variações intraespecíficas observadas nas diferentes métricas e espécies reforçam a importância de considerar fatores fenológicos, ecológicos e de visibilidade na interpretação dos resultados. A aplicação do método de bootstrap pareado permitiu avaliar de forma robusta a significância estatística das diferenças sazonais, revelando que nem todas as espécies respondem da mesma forma às variações climáticas e visuais nas imagens analisadas.

A classe ep35 (*Euterpe precatoria* Mart. produtivo) apresentou desempenho significativamente superior no período seco, possivelmente em razão da maior visibilidade dos cachos em estágios fenológicos iniciais. Em contrapartida, espécies como o murumuru (au13), com ocorrência preferencial em estratos inferiores, apresentaram menor desempenho, evidenciando como a posição vertical no dossel e a cobertura por copas superiores podem reduzir a visibilidade nas imagens RGB. Esses achados destacam que a detecção automática em florestas tropicais está fortemente condicionada à interação entre as características ecológicas das espécies no período da coleta das imagens.

Nesse contexto, este estudo oferece subsídios relevantes para a adoção de estratégias mais eficientes de coleta de imagens, com objetivo de capturar de forma mais representativa a complexidade estrutural da floresta amazônica. A escolha do período de aquisição das imagens por RPA deve ser compreendida como uma decisão metodológica crítica, e não meramente operacional. Ao demonstrar que a acurácia dos modelos de detecção pode variar substancialmente conforme o período do ano, os resultados aqui apresentados contribuem para o planejamento de campanhas de coleta mais assertivas, com potencial para melhorar a representatividade das espécies nos conjuntos de dados e, consequentemente, a qualidade dos modelos treinados. Essa perspectiva é fundamental para o avanço de sistemas de monitoramento florestal automatizados e de alta resolução, especialmente em biomas tão heterogêneos quanto a Amazônia.

## CAPÍTULO III

### DISTRIBUIÇÃO DA DENSIDADE E PROBABILIDADE DE OCORRÊNCIA DE 14 ESPÉCIES DE PALMEIRAS NA REGIÃO AMAZÔNICA

#### RESUMO

A Amazônia abriga uma das maiores diversidades de palmeiras do planeta, desempenhando um papel fundamental tanto do ponto de vista ecológico quanto socioeconômico. Diversas espécies estão inseridas em cadeias produtivas estratégicas, fornecendo recursos para as indústrias alimentícia (óleos, frutos, polpas), cosmética (extratos e ativos naturais), farmacêutica (compostos bioativos) e de bioenergia (produção de biocombustíveis e biomassa), entre outras. Esse potencial, embora expressivo, ainda é subaproveitado, e o conhecimento espacial sobre a distribuição e a densidade das espécies pode fornecer informações essenciais para o manejo florestal sustentável, a valoração dos serviços ecossistêmicos e o planejamento territorial em nível regional. Este estudo teve como objetivo estimar a densidade e a distribuição espacial de 14 espécies de palmeiras nativas da Amazônia ocidental brasileira, integrando dados de sensoriamento remoto e algoritmos de aprendizado de máquina. Foram utilizadas ortofotos RGB adquiridas por drones, nas quais o modelo de detecção automática YOLOv10x identificou mais de 560 mil indivíduos. As detecções foram convertidas em densidade (indivíduos por hectare) e utilizadas como variável dependente em modelos de *Random Forest*, treinados com variáveis ambientais como precipitação, temperatura, relevo, solo e vegetação. Os modelos apresentaram desempenho preditivo satisfatório ( $R^2$  entre 0,48 e 0,85), com destaque para a importância da precipitação mínima, TWI, elevação e latitude. Os mapas preditivos gerados revelaram padrões distintos de ocorrência por espécie e permitiram identificar áreas prioritárias para diferentes cadeias produtivas. Conclui-se que a integração entre geotecnologias, *deep learning* e modelagem ambiental representa uma ferramenta eficaz para o planejamento territorial, a valorização da socio-biodiversidade e o fortalecimento da bioeconomia na Amazônia.

**Palavras-chave:** palmeiras amazônicas, bioeconomia, sensoriamento remoto, modelagem ambiental, *Random Forest*

## ABSTRACT

The Amazon harbors one of the greatest diversities of palm species on the planet, playing a fundamental role from both ecological and socioeconomic perspectives. Several species are part of strategic value chains, supplying raw materials for the food (oils, fruits, pulps), cosmetic (extracts and natural actives), pharmaceutical (bioactive compounds), and bioenergy (biofuels and biomass) industries, among others. Although this potential is significant, it remains underutilized, and spatial knowledge of species distribution and density can provide essential information for sustainable forest management, ecosystem service valuation, and regional territorial planning. This study aimed to estimate the density and spatial distribution of 14 native palm species in the Western Brazilian Amazon by integrating remote sensing data and machine learning algorithms. RGB orthomosaics acquired by drones were used, in which the YOLOv10x deep learning model automatically detected more than 560,000 individual palms. These detections were converted into density values (individuals per hectare) and used as the dependent variable in *Random Forest* models trained with environmental covariates such as precipitation, temperature, topography, soil, and vegetation. The models showed satisfactory predictive performance ( $R^2$  ranging from 0.48 to 0.85), with minimum precipitation, topographic wetness index (TWI), elevation, and latitude being among the most important predictors. The predictive maps revealed distinct occurrence patterns by species and enabled the identification of priority areas for different value chains. We conclude that the integration of geotechnologies, deep learning, and environmental modeling represents an effective tool for territorial planning, socio-biodiversity enhancement, and the promotion of the bioeconomy in the Amazon.

**Keywords:** Amazonian palms, bioeconomy, remote sensing, environmental modeling, *Random Forest*

## 1 INTRODUÇÃO

A estimativa precisa do potencial produtivo de espécies vegetais nativas, especialmente daquelas com relevância socioeconômica como as palmeiras amazônicas, depende diretamente do conhecimento sobre a favorabilidade de ocorrência das espécies em diferentes ambientes ecológicos. Compreender os padrões espaciais que determinam a presença, abundância e vigor dessas espécies é essencial para subsidiar estratégias de manejo sustentável, zoneamento ecológico-econômico e avaliação do potencial de exploração florestal não madeireira (Phillips et al., 2006; Loyola, 2014). As palmeiras desempenham papel ecológico e econômico estratégico na região amazônica, sendo fontes de alimentos, óleos, fibras e madeira, além de sustentarem cadeias produtivas de base extrativista (Kahn & de Granville, 1992; Henderson, 2000).

No entanto, a distribuição dessas espécies não é homogênea no espaço, variando conforme fatores edáficos, topográficos, climáticos e antrópicos. O mapeamento da favorabilidade ambiental, entendido como a estimativa da probabilidade de ocorrência ou desempenho ótimo de uma espécie em determinada região, surge como ferramenta essencial para priorizar áreas com maior aptidão ecológica e econômica (Soberón & Peterson, 2005). Modelos de distribuição potencial baseados em dados ambientais têm sido amplamente utilizados nesse contexto (Elith & Leathwick, 2009), embora enfrentem limitações relacionadas à escala de aplicação, necessidade de grandes bases de dados e dificuldade de atualização em áreas extensas.

Neste cenário, o sensoriamento remoto desponta como uma alternativa tecnológica promissora, permitindo o monitoramento contínuo e em larga escala da vegetação com alta resolução espacial, temporal e espectral (Pettorelli et al., 2014; Turner et al., 2003). A utilização de imagens orbitais e de RPAs (sistemas aéreos não tripulados), aliada a algoritmos de aprendizado de máquina, tem avançado na detecção automática de indivíduos arbóreos e na estimativa de atributos estruturais, como altura, área de copa e densidade populacional (Veras et al., 2023; Duncanson et al., 2022). Tais atributos estão diretamente relacionados ao potencial produtivo das espécies, sendo cruciais para inferências sobre produtividade e biomassa.

Ao integrar variáveis biofísicas derivadas de sensores remotos a modelos preditivos de favorabilidade, torna-se possível identificar zonas prioritárias para o uso sustentável, reduzindo custos operacionais, tempo de campo e riscos associados a inventários convencionais (Zhang et al., 2021). O sensoriamento remoto, portanto, representa um avanço significativo na transição de abordagens qualitativas para estimativas quantitativas,



especialmente explícitas e replicáveis, contribuindo estrategicamente para o planejamento e a gestão racional dos recursos florestais amazônicos.


Neste contexto, o presente estudo tem como objetivo estimar a densidade populacional de palmeiras nativas que ocorrem no oeste da Amazônia brasileira, a partir da integração de variáveis ambientais derivadas de sensoriamento remoto e técnicas de modelagem preditiva. Essa abordagem visa oferecer subsídios científicos para a avaliação da favorabilidade de ocorrência das espécies em diferentes condições ecológicas, promovendo o uso sustentável e estratégico desses recursos.

## 2 MATERIAIS E MÉTODOS

### 2.1 VISÃO GERAL DA METODOLOGIA APLICADA

A metodologia consistiu na integração de dados de densidade de indivíduos detectados pelo modelo YOLOv10X com variáveis ambientais derivadas de sensoriamento remoto. Essas variáveis foram organizadas em um conjunto multivariado (*stack*) e, juntamente com os dados de densidade espacial, foram utilizadas para treinar o modelo *Random Forest*. A validação do modelo foi realizada por meio de uma abordagem de bootstrap com reposição, permitindo estimativas robustas de desempenho a partir de múltiplas amostragens. As previsões resultantes foram espacializadas em células de 100 metros, possibilitando a geração de mapas contínuos de densidade e a avaliação da acurácia do modelo com base em métricas estatísticas. O produto final oferece uma representação espacial detalhada da distribuição estimada das espécies na área de estudo (FIGURA 29).

FIGURA 29 - FLUXO METODOLÓGICO PARA ESTIMATIVA DA DENSIDADE DE PALMEIRAS, ILUSTRANDO A EXTRAÇÃO DAS VARIÁVEIS PREDITORAS AMBIENTAIS E O PROCESSO DE MODELAGEM UTILIZADO PARA GERAR AS ESTIMATIVAS ESPACIAIS DE DENSIDADE.




FONTE: o autor (2025).

## 2.2 ÁREA DE ESTUDO

A área de estudo abrange a porção ocidental da Amazônia brasileira, englobando partes dos Estados do Acre, Amazonas, Rondônia e Roraima (FIGURA 30). Essa região caracteriza-se por uma ampla diversidade de paisagens naturais, englobando desde florestas densas de terra firme até áreas de baixios alagáveis, além de variações altimétricas e edáficas que contribuem para uma rica heterogeneidade ambiental. Situada entre as latitudes aproximadas de 1°N a 12°S e longitudes de 58°W a 74°W, a área cobre extensas porções de floresta tropical úmida, com elevado índice de biodiversidade, incluindo espécies de palmeiras de importância ecológica e econômica. O clima predominante é do tipo equatorial (Af, segundo Köppen-Geiger), com elevada pluviosidade anual, geralmente superior a 2.000 mm, e temperaturas médias variando entre 22,4 °C e 30 °C ao longo do ano. Além de sua relevância ecológica, a região também é estratégica para o monitoramento de mudanças ambientais, manejo florestal e estudos sobre a dinâmica de espécies nativas, como as palmeiras. A escolha desta área para o estudo se justifica pela representatividade ecológica, pela disponibilidade de imagens aéreas de alta resolução e pela existência de variações ambientais suficientes para alimentar modelos preditivos baseados em variáveis edafoclimáticas.

FIGURA 30 - LOCALIZAÇÃO DA ÁREA DE ESTUDO. EM VERDE ÁREA OCUPADA PELA FLORESTA AMAZÔNICA, EM AMARELO ÁREA DE TRANSIÇÃO DE FLORESTA PARA CERRADO, NOS ESTADOS DA AMAZÔNIA LEGAL. A ÁREA APROXIMADA DETALHA A MALHA DAS DENSIDADES PREDITAS PELO YOLOV10X



FONTE: o autor (2025).


## 2.3 DADOS

### 2.3.1 Densidade das Palmeiras

A etapa inicial consistiu na detecção automática de copas de palmeiras em ortofotos RGB por meio do modelo YOLOv10x, utilizando o conjunto de pesos treinados com melhor desempenho, conforme definido no Capítulo 1 deste trabalho. Para garantir maior confiabilidade nas detecções, foram consideradas apenas as *bounding boxes* com nível de confiança igual ou superior a 0,01. Foram desconsiderados os indivíduos localizados na faixa de 50 metros a partir da borda das ortofotos, com o objetivo de eliminar zonas propensas a distorções geométricas e artefatos ópticos que poderiam comprometer a acurácia da detecção nas extremidades das imagens. As detecções resultantes foram convertidas em pontos georreferenciados, representando os centros das copas identificadas. Em seguida, foi gerado um grid regular de 1 hectare, no qual as contagens de palmeiras por célula resultaram em valores de densidade (indivíduos.ha<sup>-1</sup>). Esses valores foram atribuídos aos centros de cada célula, permitindo a construção de um mapa temático contínuo de densidade, utilizado como variável dependente para a construção do modelo de predição da densidade e de palmeiras.

No total, foram consideradas 14 espécies de palmeiras nativas da Amazônia brasileira, selecionadas por sua relevância ecológica, importância socioeconômica e representatividade nas áreas amostradas. As espécies incluídas foram: tucumã (*Astrocaryum aculeatum*, aa14), jaci (*Attalea butyracea*, ab10), jauari (*Astrocaryum jauari*, aj82), inajá (*Attalea maripa*, am16), urucuri (*Attalea phalerata*, ap12), babaçu (*Attalea speciosa*, as48), cocão (*Attalea tessmannii*, at34), murumuru (*Astrocaryum ulei*, au13), açaí solteiro (*Euterpe precatoria*, ep01), açaí produtivo (*ep35*), paxiuba (*Socratea exorrhiza*, se04), buritirana (*Mauritiella armata*, ma79), buriti (*Mauritia flexuosa*, mf09), bacaba (*Oenocarpus bacaba*, ob70) e patauá (*Oenocarpus bataua*, ob19). As espécies foram agrupadas em 4 categorias principais de uso: alimentícios, biocombustíveis, cosméticos e outros, com base em suas aplicações conhecidas segundo literatura técnica e levantamentos etnobotânicos regionais (FIGURA 31). Essa classificação visa destacar a multifuncionalidade dessas palmeiras, que desempenham papel essencial na subsistência de populações locais, na geração de renda e no fornecimento de matérias-primas para diferentes cadeias produtivas.

FIGURA 31 - CLASSIFICAÇÃO FUNCIONAL DE PALMEIRAS AMAZÔNICAS EM QUATRO CATEGORIAS PRINCIPAIS DE USO EM DIFERENTES CADEIAS PRODUTIVAS: ALIMENTÍCIOS, BIOCOMBUSTÍVEIS, COSMÉTICOS E OUTROS COM BASE EM SUA INSERÇÃO EM DIFERENTES CADEIAS PRODUTIVAS.




### 2.3.2 Vegetação, Pedologia e Relevô

As informações sobre cobertura vegetal (FIGURA 32a) foram obtidas a partir da base de dados de vegetação do Instituto Brasileiro de Geografia Estatística (IBGE), estruturada em meio digital com escala de 1:250.000 e compatível com o recorte ao milionésimo. Esta base integra o mapeamento sistemático do território brasileiro, com consistência geométrica e padronização voltada ao uso em Sistemas de Informação Geográfica (SIG). O conjunto inclui mapas vetoriais, documentos descritivos e legendas que classificam e identificam a vegetação brasileira, tanto atual quanto pretérita, utilizando uma abordagem fisionômico-ambiental adaptada à tipologia universal proposta pela UNESCO. A base contempla informações sobre os principais tipos de cobertura vegetal e biomas existentes no país, permitindo distinguir entre diferentes formações florestais, savânicas e campestres. Neste estudo, a tipologia fisionômica da vegetação foi utilizada como variável categórica no



modelo de predição da densidade de palmeiras, contribuindo para caracterizar os padrões estruturais e ecológicos da paisagem amazônica.

FIGURA 32 - MAPAS TEMÁTICOS DE VARIÁVEIS AMBIENTAIS UTILIZADAS NA MODELAGEM DA DENSIDADE DE PALMEIRAS. (a) TIPOS DE VEGETAÇÃO, CONFORME CLASSIFICAÇÃO FISIONÔMICO-AMBIENTAL ADAPTADA DA UNESCO (IBGE, 2023). (b) CLASSES DE SOLOS SEGUNDO O SISTEMA BRASILEIRO DE CLASSIFICAÇÃO DE SOLOS (SiBCS) (IBGE, 2023). (c) MODELO TOPOGRÁFICO DERIVADO DO SRTM, REPRESENTANDO OS PADRÕES DE RELEVO DA ÁREA DE ESTUDO.



FONTE: o autor (2025).

As informações edáficas (FIGURA 32b) foram obtidas a partir da base de dados de solos do IBGE, disponibilizada em meio digital na escala de 1:250.000, com recorte ao milionésimo e estrutura padronizada para uso em Sistemas de Informação Geográfica (SIG). A base inclui mapas temáticos e arquivos vetoriais que representam a distribuição e classificação dos solos brasileiros, com informações técnicas e interpretativas baseadas no Sistema Brasileiro de Classificação de Solos (SiBCS) (EMBRAPA, 2006). No presente estudo, as classes de solo foram utilizadas como variáveis categóricas no modelo de predição da densidade de palmeiras, considerando sua influência sobre aspectos ecológicos e edáficos da paisagem amazônica.


Os dados de elevação (FIGURA 32c) utilizados neste estudo foram obtidos a partir do Modelo Digital de Elevação da missão *Shuttle Radar Topography Mission* (SRTM), versão 3 (SRTM Plus), disponibilizado pela NASA/JPL. Este conjunto de dados fornece informações topográficas com resolução espacial de 1 arco-segundo (~30 metros), cobrindo a maior parte das áreas continentais entre 60°N e 56°S (Farr et al., 2007). A versão utilizada passou por um processo de preenchimento de vazios com dados de código aberto (ASTER GDEM2, GMTED2010 e NED), garantindo maior completude e continuidade espacial em relação a versões anteriores que apresentavam lacunas ou dependiam de fontes comerciais. A

partir do modelo de elevação, foram derivadas duas variáveis topográficas principais: a altitude (m) e a declividade (graus), calculada por meio do gradiente do terreno. Essas variáveis foram utilizadas como covariáveis contínuas no modelo preditivo, contribuindo para representar a influência do relevo na distribuição espacial das palmeiras.

### 2.3.3 Precipitação

As variáveis de precipitação (FIGURA 33) utilizadas neste estudo foram derivadas do conjunto de dados CHIRPS (*Climate Hazards Group InfraRed Precipitation with Station data*), desenvolvido pelo *Climate Hazards Center* da Universidade da Califórnia, Santa Barbara (UCSB). O CHIRPS é um produto de precipitação quase-global com mais de 30 anos de cobertura temporal, combinando observações de satélite com dados de estações meteorológicas *in situ*. Com resolução espacial de  $0.05^\circ$  ( $\sim 5$  km), a série oferece uma estimativa diária da chuva acumulada, ideal para análises de tendências e monitoramento de secas sazonais, especialmente em regiões com baixa densidade de observações. Para este estudo, foram utilizados dados do período de 1981 a 2025, dos quais foram derivadas as estatísticas mensais de precipitação mínima, média e máxima, utilizadas como covariáveis no modelo de predição da densidade de palmeiras.

FIGURA 33 - MAPAS TEMÁTICOS DAS VARIÁVEIS CLIMÁTICAS DE PRECIPITAÇÃO UTILIZADAS NA MODELAGEM DA DENSIDADE DE PALMEIRAS. (a) PRECIPITAÇÃO MÍNIMA MÉDIA MENSAL (mm). (b) PRECIPITAÇÃO MÉDIA MENSAL (mm). (c) PRECIPITAÇÃO MÁXIMA MÉDIA MENSAL (mm). VALORES DERIVADOS DO CONJUNTO DE DADOS CHIRPS (*CLIMATE HAZARDS GROUP INFRARED PRECIPITATION WITH STATION DATA*), COM RESOLUÇÃO ESPACIAL DE  $0.05^\circ$  E SÉRIE TEMPORAL DE 1981 A 2025.




FONTE: o autor (2025).

### 2.3.4 Temperatura

As variáveis de temperatura (FIGURA 34) utilizadas neste estudo foram obtidas a partir do conjunto de dados CHIRTS-daily (*Climate Hazards InfraRed Temperature with Stations – daily*), desenvolvido pelo *Climate Hazards Center* - UCSB. Esse produto fornece estimativas diárias de temperatura máxima (Tmax) e mínima (Tmin) do ar a 2 metros de

altura, em uma grade de alta resolução espacial ( $0.05^\circ \times 0.05^\circ$ ), cobrindo a faixa latitudinal entre  $60^\circ\text{S}$  e  $70^\circ\text{N}$  (Verdin et al., 2020).

FIGURA 34 - MAPAS TEMÁTICOS DAS VARIÁVEIS CLIMÁTICAS DE TEMPERATURA UTILIZADAS NA MODELAGEM DA DENSIDADE DE PALMEIRAS. (a) TEMPERATURA MÍNIMA MÉDIA MENSAL ( $^\circ\text{C}$ ). (b) TEMPERATURA MÉDIA MENSAL ( $^\circ\text{C}$ ). (c) TEMPERATURA MÁXIMA MÉDIA MENSAL ( $^\circ\text{C}$ ). VALORES DERIVADOS DO CONJUNTO DE DADOS CHIRTS-DAILY (*CLIMATE HAZARDS INFRARED TEMPERATURE WITH STATIONS – DAILY*), COM RESOLUÇÃO ESPACIAL DE  $0.05^\circ$  E SÉRIE TEMPORAL COMPREENDENDO OS ANOS DE 1983 A 2016.



FONTE: o autor (2025).

O CHIRTS-daily foi projetado para capturar extremos térmicos e a variabilidade espaço-temporal da temperatura em regiões com baixa densidade de estações meteorológicas, como a Amazônia. Ele é gerado pela fusão do produto mensal CHIRTSmax (Funk et al., 2019), que representa um conjunto climatológico de alta qualidade da temperatura máxima mensal, com os dados diários da reanálise ERA5 do ECMWF (*European Centre for Medium-Range Weather Forecasts*). O resultado é uma série de dados diários que retém tanto a estrutura espacial do CHIRTSmax quanto a variabilidade diária derivada do ERA5 (ECMWF, 2025).


### 2.3.5 Hidrografia e Índice Topográfico de Umidade

O Índice Topográfico de Umidade (TWI) foi utilizado neste estudo como variável *proxy* para representar a propensão do terreno em acumular umidade superficial, permitindo distinguir áreas potencialmente mais úmidas (baixios) de regiões de terra firme. O cálculo foi realizado na plataforma Google Earth Engine (GEE), com apoio da biblioteca geemap em ambiente Python. A declividade do terreno foi derivada a partir do modelo digital de elevação SRTM (USGS/SRTMGL1\_003), com resolução espacial de 30 metros. Já a área de contribuição hidrológica foi estimada com base no produto MERIT Hydro v1.0.1, um mapa global de direções de fluxo com resolução de 3 segundos de arco ( $\sim 90$  m no equador), construído a partir do modelo MERIT DEM e de dados complementares de corpos d'água,



como G1WBM, Global Surface Water Occurrence (GSWO) e OpenStreetMap (Yamazaki et al., 2019) (FIGURA 35).

FIGURA 35 - MAPAS TEMÁTICOS DE HIDROGRAFIA UTILIZADOS NA MODELAGEM DA DENSIDADE DE PALMEIRAS. (a) REDE HIDROGRÁFICA DETALHADA DA ÁREA DE ESTUDO, DESTACANDO OS PRINCIPAIS RIOS DA REGIÃO E SEUS AFLUENTES. (b) ÍNDICE DE UMIDADE TOPOGRÁFICA (TWI), DERIVADO DE DADOS DO SRTM E CALCULADO COM BASE NA DECLIVIDADE E ACUMULAÇÃO DE FLUXO. (c) DELIMITAÇÃO DAS BACIAS HIDROGRÁFICAS PRESENTES NA ÁREA DE ESTUDO (ANA, 2025).



O MERIT Hydro representa um avanço significativo em relação a bases hidrológicas anteriores por aplicar um algoritmo que minimiza erros de fluxo causados por imperfeições no modelo de elevação, resultando em redes fluviais mais precisas e realistas, mesmo em regiões tropicais complexas. Neste estudo, o MERIT Hydro foi utilizado para derivar a camada de acumulação de fluxo, a qual foi combinada com a declividade do terreno para o cálculo do Índice Topográfico de Umidade (TWI), conforme a fórmula clássica. Para evitar instabilidades numéricas durante o cálculo, os valores de acumulação de fluxo menores ou iguais a zero foram substituídos por 1. O TWI foi então estimado com base na Equação 1.

$$TWI = \ln \left( \frac{A_s}{\tan(\beta)} \right) \quad (1)$$

Em que,  $A_s$  é a acumulação de fluxo obtida da base MERIT Hydro, representando o número de células a montante que drenam para cada célula (variável substituta da área de contribuição específica).  $\beta$  é a declividade derivada do modelo SRTM, expressa em graus e posteriormente convertida em radianos.  $\tan(\beta)$  Representa a capacidade de escoamento superficial. O valor 0,001 foi adicionado ao denominador como fator de correção numérica para evitar divisões por zero em áreas planas.

O TWI foi reclassificado em quatro zonas hidrotopográficas distintas, adotando-se limites fixos para evitar sobreposição entre classes. As categorias foram definidas da seguinte forma: terra firme ( $TWI < 6,0$ ), representando áreas altas e bem drenadas; transição seca ( $6,0 \leq TWI < 10,0$ ), correspondendo a regiões com leve acúmulo de umidade; transição úmida ( $10,0 \leq TWI < 14,0$ ), indicativa de áreas sazonalmente alagadas; e baixio ou várzea ( $TWI \geq 14,0$ ), referentes a setores planos e sujeitos a inundação permanente ou prolongada. Essa abordagem permitiu a regionalização espacial contínua do gradiente de umidade do terreno com base em critérios hidrotopográficos consistentes.

#### 2.4 MODELAGEM DA DENSIDADE COM *RANDOM FOREST*

Para a modelagem, cada pixel com densidade observada (1 ha) foi considerado como uma unidade amostral independente. A densidade de palmeiras por hectare foi utilizada como variável dependente ( $Y$ ), enquanto os valores das variáveis ambientais extraídas, como precipitação, temperatura, solo, vegetação, altitude, declividade e TWI, foram tratados como covariáveis ( $X_1, X_2, \dots, X_n$ ). O conjunto de dados resultante foi utilizado para ajustar um modelo de regressão por florestas aleatórias (*Random Forest Regression*), reconhecido por sua robustez, estabilidade e capacidade de capturar relações não lineares entre variáveis ambientais e padrões de densidade.

A validação do modelo foi conduzida por meio de um procedimento de bootstrap com reposição, com 100 iterações independentes. Em cada iteração, um subconjunto de amostras foi selecionado aleatoriamente com reposição para treinar o modelo, esse subconjunto é denominado "*in-bag*". As observações não selecionadas, em média cerca de 36,8% do total, foram utilizadas como conjunto de validação interna (*out-of-bag*). Essa abordagem incorpora uma forma eficiente de validação cruzada dentro do próprio algoritmo, sem a necessidade de uma divisão fixa entre treino e teste.

A performance do modelo foi avaliada com base em métricas tradicionais, como o erro médio quadrático (RMSE) (Equação 2) e o coeficiente de determinação ( $R^2$ ) (Equação 3), bem como pela estimativa do viés (bias) das predições (Equação 4), que permite avaliar a tendência sistemática do modelo em superestimar ou subestimar a densidade observada,

Viés (Bias)

$$Bias = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i) \quad (2)$$

Erro médio quadrático (RMSE)



$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (3)$$

Coeficiente de determinação ( $R^2$ )

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

Em que,  $y_i$  são os valores observados de densidade,  $\hat{y}_i$  são os valores preditos pelo modelo,  $\bar{y}$  é a média dos valores observados,  $n$  é o número de observações no conjunto de validação. Ao final das 100 iterações de bootstrap, foram computadas as estatísticas descritivas (média, mínimo, máximo e desvio padrão) de cada métrica, permitindo avaliar de forma robusta a qualidade preditiva do modelo.

#### 2.4.1 Mapas preditivos

Para a etapa de espacialização da densidade das espécies, os modelos *Random Forest* treinados foram aplicados com o objetivo de gerar mapas preditivos de densidade (indivíduos por hectare) nos estados do Acre, Rondônia e Roraima. A aplicação principal concentrou-se no estado do Acre, que apresentou maior abrangência e diversidade nos dados de entrada, fator determinante para a obtenção de predições mais robustas e confiáveis, minimizando possíveis vieses associados à escassez ou concentração geográfica das amostras. Nesse estado, as espécies foram agrupadas conforme sua principal forma de uso, permitindo uma análise exploratória do potencial produtivo voltado ao abastecimento de diferentes cadeias industriais, como a cadeia alimentícia, por exemplo, com espécies empregadas na produção de polpas e óleos comestíveis. Nos estados de Rondônia e Roraima, a predição foi restrita às espécies cuja ocorrência é conhecida nesses territórios, respeitando os limites biogeográficos observados. Embora os dados provenientes da Região Sul do Amazonas tenham sido incorporados ao treinamento do modelo, não foi realizada a espacialização para nesse estado devido à baixa representatividade espacial das amostras, concentradas em uma única região, o que comprometeria a validade da extrapolação para o restante do território do Amazonas. Essa estratégia metodológica buscou equilibrar representatividade amostral e robustez preditiva,

assegurando que os mapas gerados refletissem padrões ecológicos reais e evitassem inferências espúrias decorrentes de lacunas geográficas nos dados.

### 3 RESULTADOS

#### 3.1 ANÁLISE DESCRITIVA

A partir da aplicação do modelo YOLOv10x pré-treinado sobre as imagens RGB adquiridas por RPA, foram detectados um total de 562011 indivíduos de palmeiras nas áreas amostradas. Considerando a taxa média de precisão do modelo, estimada em 80% com base na validação cruzada. A densidade das espécies variou de 1,35 palmeiras por hectare a 6,21 palmeiras por hectare.

TABELA 9 - ESTATÍSTICAS DESCRITIVAS DE DENSIDADE E MORFOMETRIA DE 14 ESPÉCIES DE PALMEIRAS AMAZÔNICAS DETECTADAS EM ORTOFOTOS RGB OBTIDAS POR DRONES, UTILIZANDO O MODELO YOLOV10X.

| Espécie                      | Densidade                              |                                         | Copas                           |                |               |               |
|------------------------------|----------------------------------------|-----------------------------------------|---------------------------------|----------------|---------------|---------------|
|                              | Média<br>(Palmeiras.ha <sup>-1</sup> ) | Máxima<br>(Palmeiras.ha <sup>-1</sup> ) | Área média<br>(m <sup>2</sup> ) | Ø médio<br>(m) | Ø mín.<br>(m) | Ø máx.<br>(m) |
| <i>Astrocaryum aculeatum</i> | 2,79                                   | 24                                      | 37,17                           | 5,91 ± 1,74    | 1,96          | 14,98         |
| <i>Attalea butyracea</i>     | 3,37                                   | 56                                      | 66,86                           | 7,88 ± 2,48    | 2,14          | 20,52         |
| <i>Astrocaryum jauari</i>    | 1,85                                   | 19                                      | 62,35                           | 7,65 ± 2,32    | 2,92          | 16,40         |
| <i>Attalea maripa</i>        | 6,21                                   | 210                                     | 64,92                           | 7,92 ± 1,81    | 2,17          | 20,47         |
| <i>Attalea phalerata</i>     | 2,06                                   | 28                                      | 68,63                           | 8,10 ± 2,32    | 2,34          | 19,62         |
| <i>Attalea speciosa</i>      | 5,62                                   | 30                                      | 83,35                           | 8,91 ± 2,33    | 2,08          | 20,48         |
| <i>Attalea tessmannii</i>    | 1,35                                   | 8                                       | 79,23                           | 8,78 ± 2,17    | 2,79          | 20,40         |
| <i>Astrocaryum ulei</i>      | 2,57                                   | 26                                      | 31,60                           | 5,44 ± 1,61    | 1,75          | 19,52         |
| <i>Euterpe precatoria</i>    | 4,90                                   | 97                                      | 14,13                           | 3,69 ± 0,80    | 1,24          | 14,53         |
| <i>Euterpe precatoria</i> *  | 2,13                                   | 30                                      | 19,20                           | 4,33 ± 0,85    | 1,59          | 14,31         |
| <i>Mauritiella armata</i>    | 4,38                                   | 176                                     | 20,37                           | 4,32 ± 1,44    | 1,62          | 17,51         |
| <i>Mauritia flexuosa</i>     | 2,72                                   | 47                                      | 42,30                           | 6,24 ± 2,03    | 1,62          | 19,88         |
| <i>Oenocarpus bataua</i>     | 2,50                                   | 38                                      | 66,10                           | 7,99 ± 2,03    | 2,24          | 20,71         |
| <i>Oenocarpus bacaba</i>     | 3,11                                   | 28                                      | 41,05                           | 6,33 ± 1,28    | 2,35          | 11,39         |
| <i>Socratea exorrhiza</i>    | 6,16                                   | 299                                     | 25,59                           | 4,94 ± 1,33    | 1,67          | 19,75         |
| Média                        | 3,45                                   | 74,40                                   | 48,19                           | 6,56 ± 1,76    | 2,03          | 18,03         |


\* = *Euterpe precatoria* produtivo, Ø = diâmetro das copas.

Com relação às variáveis dendrometrias, observou-se ampla variação na área de copa e diâmetro das palmeiras. A área média de copa variou entre 14,13 m<sup>2</sup> (*E. precatoria*) e 83,35 m<sup>2</sup> (*A. speciosa*), enquanto o diâmetro (Ø) médio das copas oscilou de 3,69 ± 0,80 m até 8,91 ± 2,33 m. A espécie *O. bataua* apresentou o maior diâmetro máximo registrado (20,71 m), enquanto o menor diâmetro mínimo foi de 1,24 m, também associado a indivíduos de *E. precatoria*.

Com base em uma análise visual exploratória, foram observados alguns padrões de distribuição espacial entre as espécies. A FIGURA 36 ilustra a disposição geográfica de algumas palmeiras na região do Alto Acre, no município de Xapuri. Nota-se que espécies como o paxiuba e o patauá tendem a ocorrer preferencialmente em áreas mais baixas do relevo, geralmente associadas à proximidade de cursos d'água e à maior disponibilidade hídrica. Já o açaí apresentou uma distribuição mais dispersa e aparentemente homogênea ao

longo da área observada, o que pode indicar maior tolerância a diferentes condições topográficas ou uma estratégia ecológica mais generalista.

FIGURA 36 - DISTRIBUIÇÃO DAS PALMEIRAS NA REGIÃO DE XAPURI, ACRE. (a) ORTOFOTO DA ÁREA DE ESTUDO. (b) MAPA TEMÁTICO DE ALTIMETRIA E PADRÃO ESPACIAL DAS ESPÉCIES ESTUDADAS.



FONTE: o autor (2025).

## 3.2 MODELAGEM DA DENSIDADE EM LARGA ESCALA


### 3.2.1 *Random Forest*

Para avaliar a capacidade preditiva dos modelos de *Random Forest* aplicados à estimativa da densidade de 15 espécies de palmeiras amazônicas, comparamos os valores observados com os valores preditos com base em variáveis ambientais extraídas via sensoriamento remoto. As métricas estatísticas utilizadas incluíram o coeficiente de determinação ( $R^2$ ), o erro quadrático médio (RMSE) e o viés médio (bias), calculados a partir de validação por bootstrap com 100 iterações. Os resultados indicaram desempenho variável entre as espécies, com valores de  $R^2$  variando entre 0.48 e 0.85, indicando moderada a alta

capacidade explicativa dos modelos (FIGURA 37). Espécies como *Attalea speciosa* (babaçu), *Attalea maripa* (inajá) e *Oenocarpus bataua* (patauá) apresentaram os melhores desempenhos preditivos, refletindo possivelmente uma maior resposta à variação ambiental capturada pelas covariáveis selecionadas. O RMSE variou entre 0,22 e 4,05 palmeiras.ha<sup>-1</sup>, enquanto os valores de bias permaneceram próximos de zero. A equação da reta de tendência entre os valores estimados e observados permitiu avaliar desvios sistemáticos do modelo em relação à linha ideal (1:1), o que revela a tendência de subestimação das maiores densidades, ao passo que o intercepto positivo da reta indica a existência de viés constante no modelo. Esses padrões refletem a dificuldade do modelo em capturar variações reais em cenários onde há menor representatividade de amostras e com altas concentrações de indivíduos no conjunto de treinamento e validação, como no caso do buriti, buritirana e paxiúba (FIGURA 37).



FIGURA 37 - RELAÇÃO ENTRE OS VALORES OBSERVADOS E PREDITOS DE DENSIDADE PARA 14 ESPÉCIES DE PALMEIRAS AMAZÔNICAS, COM BASE EM MODELOS *RANDOM FOREST*. CADA PONTO REPRESENTA UMA CÉLULA DE VALIDAÇÃO (1 ha), E A LINHA TRACEJADA INDICA A CORRESPONDÊNCIA PERFEITA (1:1). OS MODELOS FORAM AVALIADOS POR MEIO DE VALIDAÇÃO COM BOOTSTRAP (N = 100), E OS GRÁFICOS APRESENTAM OS COEFICIENTES DE DETERMINAÇÃO ( $R^2$ ), VIÉS MÉDIO (BIAS) E ERRO QUADRÁTICO MÉDIO (RMSE) PARA CADA ESPÉCIE.




FONTE: o autor (2025)

Com base na análise de importância das covariáveis nos modelos *Random Forest* (FIGURA 38), verificou-se que os principais preditores da densidade de palmeiras foram as

precipitações máxima e mínima, as temperaturas máxima e mínima, a longitude, a latitude, a elevação, a declividade e o índice topográfico de umidade (TWI). Cada uma dessas covariáveis apresentou níveis distintos de importância conforme a espécie analisada. Em contraste, as covariáveis relacionadas ao solo e à fitofisionomia vegetal mostraram menor relevância preditiva. Esses resultados evidenciam uma forte dependência das espécies em relação à disponibilidade hídrica e às condições topográficas locais, em consonância com os padrões ecológicos conhecidos das palmeiras amazônicas.

FIGURA 38 - IMPORTÂNCIA RELATIVA DAS VARIÁVEIS AMBIENTAIS UTILIZADAS NA MODELAGEM DA DENSIDADE DE PALMEIRA PELO *RANDOM FOREST*. OS VALORES REPRESENTAM A MÉDIA DA IMPORTÂNCIA DAS VARIÁVEIS AO LONGO DE 100 ITERAÇÕES DE BOOTSTRAP. AS VARIÁVEIS MAIS RELEVANTES INCLUÍRAM PRECIPITAÇÃO MÍNIMA, ÍNDICE TOPOGRÁFICO DE UMIDADE (TWI), ELEVACÃO E LATITUDE, INDICANDO A INFLUÊNCIA DE FATORES CLIMÁTICOS E TOPOGRÁFICOS NA DISTRIBUIÇÃO DAS ESPÉCIES.




FONTE: o autor (2025).

### 3.2.2 Mapas preditivos

Além da validação quantitativa, os modelos *Random Forest* treinados foram aplicados para gerar mapas de espacialização da densidade de palmeiras por hectare nos estados do Acre, Rondônia e Roraima (FIGURA 39 a 41 e ANEXOS 1 a 13). No caso do Acre, as espécies foram agrupadas conforme sua principal forma de uso, com o objetivo de facilitar uma análise exploratória do potencial produtivo voltado ao abastecimento de diferentes cadeias industriais. Os mapas resultantes evidenciam padrões regionais distintos de distribuição, permitindo identificar áreas com alta concentração de determinadas espécies, especialmente em zonas úmidas e de baixo e regiões com maior pluviosidade anual. A FIGURA 39 apresenta os mapas preditivos de densidade para as espécies com maior potencial de uso na cadeia alimentícia, como aquelas empregadas na produção de polpas e óleos comestíveis. Esses mapas permitem visualizar a distribuição espacial dessas espécies no estado do Acre, identificando regiões prioritárias para o desenvolvimento de sistemas agroindustriais voltados ao aproveitamento sustentável dos recursos florestais nativos.

FIGURA 39 - DISTRIBUIÇÃO DA DENSIDADE DAS ESPÉCIES DE PALMEIRAS QUE OCORREM NO ESTADO DO ACRE COM POTENCIAL DE UTILIZAÇÃO NA INDÚSTRIA ALIMENTÍCIA.




FONTE: o autor (2025).



A FIGURA 40 exibe os resultados preditivos para as espécies com potencial aplicação na produção de biocombustíveis. A espacialização dessas espécies contribui para a avaliação de alternativas energéticas renováveis e de baixo impacto ambiental, indicando áreas aptas à extração sustentável de óleo vegetal com fins energéticos.

FIGURA 40 - DISTRIBUIÇÃO DA DENSIDADE DAS ESPÉCIES DE PALMEIRAS QUE OCORREM NO ESTADO DO ACRE COM POTENCIAL PARA A PRODUÇÃO DE BIOCOMBUSTÍVEIS.




FONTE: o autor (2025).

As estimativas de densidade apresentaram ampla variação entre as espécies avaliadas, refletindo seus diferentes padrões ecológicos e distribuição territorial no estado do Acre. Os valores máximos de densidade foram observados para *Attalea butyracea* (29,18 palmeiras.ha<sup>-1</sup>), *Mauritia flexuosa* (25,72 palmeiras.ha<sup>-1</sup>) e *Oenocarpus bataua* (24,34 palmeiras.ha<sup>-1</sup>). Em contrapartida, *Attalea phalerata* apresentou o menor valor máximo estimado (6,34 palmeiras.ha<sup>-1</sup>), seguida por *Astrocaryum aculeatum* (9,51 palmeiras.ha<sup>-1</sup>). Esses contrastes refletem não apenas diferenças ecológicas intrínsecas entre as espécies, mas também a influência das condições ambientais locais sobre a densidade observada. Os valores mínimos estimados foram próximos de zero para a maioria das espécies, indicando grandes áreas com baixa ou nenhuma ocorrência, o que reforça a importância de abordagens espacializadas para orientar estratégias de uso e manejo. Na avaliação conjunta das espécies

com potencial para biocombustíveis, a densidade total variou entre 19,81 e 146,64 palmeiras.ha<sup>-1</sup>, evidenciando zonas de alta concentração com possível prioridade para iniciativas produtivas baseadas em aproveitamento energético.

A densidade conjunta das espécies com potencial para uso cosmético variou entre 8,91 e 53,44 palmeiras.ha<sup>-1</sup> (FIGURA 41). Esses resultados evidenciam áreas prioritárias para o desenvolvimento de cadeias produtivas voltadas à extração de óleos e manteigas vegetais com aplicação na indústria cosmética natural. Entre as espécies avaliadas, *Astrocaryum ulei* apresentou as menores estimativas de densidade (máximo de 4,88 palmeiras.ha<sup>-1</sup>), o que pode estar relacionado ao seu hábito de crescimento predominantemente no estrato inferior da floresta. Essa característica morfológica dificulta sua visibilidade em imagens aéreas, especialmente em áreas com cobertura densa de dossel.

FIGURA 41 - DISTRIBUIÇÃO DA DENSIDADE DAS ESPÉCIES DE PALMEIRAS QUE OCORREM NO ESTADO DO ACRE COM POTENCIAL PARA A UTILIZAÇÃO NA INDÚSTRIA DE COSMÉTICOS.



FONTE: o autor (2025).



#### 4 DISCUSSÃO

A análise visual preliminar dos dados motivou diretamente o objetivo desta pesquisa, ao sugerir que a distribuição espacial das palmeiras pode estar fortemente influenciada por fatores ambientais. A observação de padrões recorrentes, como a concentração de determinadas espécies em áreas mais úmidas e de relevo mais baixo, ou zonas de baixo, levantou a hipótese de que variáveis como topografia, disponibilidade hídrica, solo e clima estão potencialmente correlacionadas com a ocorrência e a densidade dos indivíduos. Diversos estudos já indicam que fatores edáficos e topográficos desempenham papel central na estruturação da vegetação amazônica e na distribuição de palmeiras, influenciando desde o estabelecimento de plântulas até a produtividade adulta (Svenning, 2001; Vormisto et al., 2004; Phillips et al., 2003). A partir dessa premissa, este trabalho buscou estruturar modelos preditivos que quantificassem tais relações, com o objetivo de identificar zonas de maior favorabilidade ecológica para as espécies estudadas e subsidiar estratégias de manejo sustentável e conservação direcionada.

A distribuição geográfica das palmeiras apresentou alta heterogeneidade (FIGURA 39 a 41 ANEXOS 1 a 13). Essa variabilidade espacial reflete os diferentes graus de adaptação ecológica das espécies, que não ocorrem de forma homogênea na paisagem, mas sim em nichos específicos de maior favorabilidade ambiental. Espécies como *Mauritia flexuosa* (buriti), *Astrocaryum aculeatum* (tucumã), *Euterpe precatoria* (açaí) e *Oenocarpus bataua* (patauá) ilustram bem essa dinâmica, com ocorrência concentrada em ambientes como áreas de várzea, baixios úmidos e solos com pouca drenagem. Diante dessa complexidade, o desenvolvimento de mapas regionalizados de densidade, como os apresentados neste estudo, torna-se uma ferramenta fundamental para a compreensão da distribuição ecológica dessas espécies. Além de enriquecer o conhecimento científico sobre a ecologia das palmeiras, esses mapas oferecem base técnica sólida para orientar ações de manejo florestal, restauração ecológica, planejamento agroextrativista e políticas públicas de conservação, contribuindo para o uso sustentável da biodiversidade amazônica.

Dentre as espécies analisadas, o açaí merece destaque por seu expressivo valor econômico e sociocultural. Considerado o produto florestal não madeireiro de maior valor comercial no Brasil, o açaí tem sustentado uma cadeia produtiva robusta, com forte impacto no desenvolvimento regional. Segundo o IBGE (2024), em 2023 a produção extrativa do fruto alcançou 238,9 mil toneladas, movimentando R\$ 853,1 milhões, com o estado do Pará responsável por 70,2% do volume nacional. Esse desempenho evidencia o enraizamento do açaí na dinâmica econômica da região Norte, consolidando-se como um vetor estratégico para

o fortalecimento da bioeconomia amazônica. Embora o Pará lidere amplamente a produção nacional de açaí, outros estados da Amazônia brasileira, como o Acre, apresentam grande potencial ainda subexplorado. No Acre, a produção ocorre predominantemente de forma extrativista, sendo essencial para a subsistência e renda de comunidades agroextrativistas. No entanto, desafios logísticos, sanitários e estruturais, como a ausência de unidades de beneficiamento, dificuldades no escoamento da produção e riscos de contaminação, ainda limitam o crescimento sustentável da cadeia (Azevedo et al., 2019). Nesse contexto, os mapas de densidade preditiva produzidos neste estudo podem ser ferramentas estratégicas para identificar áreas prioritárias de manejo, orientar investimentos em infraestrutura e apoiar políticas públicas de fomento. Ao delimitar zonas com alta concentração de açaizeiros, esses mapas permitem um planejamento territorial mais eficiente, reduzindo os custos logísticos, direcionando ações de regularização sanitária e incentivando a implantação de sistemas agroflorestais em regiões com maior aptidão natural. Com isso, contribuem para transformar o potencial produtivo regional em realidade econômica, fortalecendo cadeias de valor baseadas na sociobiodiversidade e promovendo o desenvolvimento regional com conservação ambiental.

Além do açaí, outras palmeiras também apresentam expressiva importância econômica. O babaçu (amêndoa), por exemplo, gerou R\$ 68,8 milhões em valor de produção em 2023 (IBGE, 2024). Embora inferior ao açaí em volume e valor, o babaçu representa uma fonte tradicional de renda para populações extrativistas, com uso multifuncional da palmeira nas áreas de alimentação, energia, artesanato e construção civil. Espécies como *Mauritia flexuosa* (buriti) e *Astrocaryum aculeatum* (tucumã) também têm ganhado atenção devido ao seu elevado valor nutricional e multifuncionalidade. O buriti, por exemplo, possui frutos com alto teor de carotenoides, polifenóis e tocoferóis, sendo aproveitado nas indústrias de alimentos, cosméticos e biocombustíveis (Nascimento-Silva et al., 2020). Além disso, suas fibras e pecíolos são utilizados na construção e no artesanato, enquanto a espécie contribui ecologicamente para a manutenção da umidade do solo e dos corpos hídricos (Virapongse et al., 2017).

No campo energético, embora a palma de óleo (*Elaeis guineensis*), espécie exótica de cultivo intensivo, ainda ocupe posição de destaque no Brasil, com produção superior a 200 mil toneladas de óleo em 2023 (BBF, 2023), há um potencial estratégico latente nas palmeiras nativas que permanece amplamente subaproveitado. Espécies como *Mauritia flexuosa* (buriti), *Astrocaryum aculeatum* (tucumã), *Attalea speciosa* (babaçu), *Attalea butyracea* (jaci) e *Attalea maripa* (inajá) e *Attalea phalerata* (urucuri), ocorrem amplamente distribuídas, e

apresentam altos rendimentos de óleo, (Miranda, 2014; Zuffo et al., 2016, Brito et al., 2017; Nagaishi et al., 2019, Silva et al, 2021).

A diversidade bioquímica das palmeiras amazônicas revela um enorme potencial para as indústrias cosmética e farmacêutica, setores em franca expansão que valorizam cada vez mais ingredientes naturais, sustentáveis e com origem socioculturalmente responsável. Espécies como *Mauritia flexuosa* (buriti), *Astrocaryum aculeatum* (tucumã), *Oenocarpus bataua* (patauá), *Attalea speciosa* (babaçu), *Astrocaryum murumuru* (murumuru) e *Euterpe oleracea* (açaí) já figuram como bioingredientes valorizados em formulações cosméticas, óleos, manteigas e extratos vegetais com propriedades antioxidantes, hidratantes e emolientes, além de forte apelo mercadológico associado à floresta amazônica, evidenciado pela presença desses ativos na principal feira internacional do setor, a In-Cosmetics Global, o que reforça seu reconhecimento internacional (Euler et al., 2023). No entanto, sua participação efetiva nos mercados globais ainda é modesta, limitada por cadeias produtivas pouco estruturadas, baixa agregação de valor nas comunidades fornecedoras e escassez de pesquisas aplicadas sobre suas propriedades e distribuição ecológica (Euler et al., 2023; Ribeiro & Soares-Filho, 2022).

Nesse contexto, os mapas de densidade espacial gerados neste estudo ganham relevância estratégica como ferramentas fundamentais para o planejamento territorial e o fortalecimento de cadeias produtivas baseadas nas palmeiras nativas. Ao indicar com precisão as regiões de maior concentração por espécie, esses mapas permitem identificar áreas prioritárias para o manejo sustentável e o desenvolvimento de arranjos produtivos locais voltados à produção de alimentos, óleos vegetais, cosméticos, fármacos, biocombustíveis, fibras entre outros. A aplicação desses dados pode orientar políticas públicas, fomentar a bioeconomia regional e estimular modelos produtivos que integrem conservação ambiental, inclusão social e inovação tecnológica. Assim, as palmeiras deixam de ser vistas apenas como recurso extrativista e passam a ocupar um lugar estratégico em diversos segmentos industriais, oferecendo uma base concreta para a valorização econômica da sociobiodiversidade amazônica e para a construção de alternativas sustentáveis ao uso predatório da floresta.

## 5 CONCLUSÃO

Este estudo demonstrou o potencial do uso de imagens de drones associadas a modelos de detecção automática (YOLOv10x) e algoritmos de aprendizado de máquina (*Random Forest*) para mapear, em larga escala, a densidade e a distribuição de palmeiras amazônicas. A modelagem com *Random Forest* apresentou bom desempenho preditivo, com valores de  $R^2$  entre 0,48 e 0,85, evidenciando a robustez do modelo em capturar a influência de variáveis climáticas e topográficas, especialmente precipitação, declividade, elevação e índice topográfico de umidade. Os mapas preditivos gerados permitiram identificar zonas prioritárias de ocorrência para diferentes usos industriais, como alimentação, biocombustíveis e cosméticos, refletindo padrões espaciais distintos e reforçando a importância de abordagens regionalizadas para o manejo e a valorização das espécies nativas.

Os resultados aqui apresentados oferecem subsídios práticos e científicos para subsidiar políticas públicas voltadas ao ordenamento territorial, à bioeconomia e à valorização da sociobiodiversidade amazônica. Ao indicar áreas com maior densidade e potencial produtivo, os mapas gerados podem orientar investimentos em infraestrutura, agroindustrialização, regularização sanitária e capacitação de comunidades locais. O uso integrado de geotecnologias e modelos de inteligência artificial e aprendizado de máquina representam uma ferramenta promissora para planejar o uso sustentável da floresta, ampliar o valor agregado dos produtos nativos e promover o desenvolvimento socioeconômico com base na conservação.

## REFERÊNCIAS BIBLIOGRÁFICAS

- Agência Nacional das Águas. (2025). Catálogo de Metadados da ANA. <https://metadados.snirh.gov.br/geonetwork/srv/por/catalog.search#/home>
- Albertz, J. A look back 140 Years of “Photogrammetry” Some Remarks on the History of Photogrammetry. *Photogrammetric Engineering & Remote Sensing*, v. 73, n. 5, p. 504-506, 2007.
- Albuquerque, M. L. S., Guedes, I., Alcantara Jr., P., Moreira, S. G. C., Barbosa Neto, N. M., Correa, D. S., & Zilio, S. C. (2005). Characterization of Buriti (*Mauritia flexuosa* L.) oil by absorption and emission spectroscopies. *Journal of the Brazilian Chemical Society*, 16(6a). <https://doi.org/10.1590/s0103-50532005000700004>
- Alif, M. A. R., & Hussain, M. (2024). YOLOv1 to YOLOv10: A comprehensive review of YOLO variants and their application in the agricultural domain. *arXiv preprint arXiv:2406.10139*. <https://doi.org/10.48550/arXiv.2406.10139>
- Alvarez-Loayza, P.; White JR, J. F.; Torres, M. S.; Balslev, H.; Kristiansen, T.; Svenning, J. C.; Gil, N. Light converts endosymbiotic fungus to pathogen, influencing seedling survival and niche-space filling of a common tropical tree, *Iriartea deltoidea*. *PloS one*, v. 6, n. 1, p. e16386, 2011. Doi: 10.1371/journal.pone.0016386
- Arce, L. S. D., Osco, L. P., de Arruda, M. dos S., Furuya, D. E. G., Ramos, A. P. M., Aoki, C., Pott, A., Fatholahi, S., Li, J., de Araújo, F. F., Gonçalves, W. N., & Junior, J. M. (2021). *Mauritia flexuosa* palm trees airborne mapping with deep convolutional neural network. *Scientific Reports*, 11(1), 1–13. <https://doi.org/10.1038/s41598-021-98522-7>
- Azevedo, H. S. F. da S., Azevedo, J. M. A. de, Rocha, A. A. da, Wadt, L. H. de O., & Campos, T. de. (2019). Extrativismo do açaizeiro *Euterpe precatoria* Mart. no Acre. In A. Siviero, R. C. Santos, & E. P. L. Mattar (Orgs.), *Conservação e tecnologias para o desenvolvimento agrícola e florestal no Acre* (Cap. 5, pp. 162–165). Ifac.
- Bernal, R.; Torres, C.; García, N.; Isaza, C.; Navarro, J.; Vallejo, M. I.; Galeano, G.; Balslev, H. Palm management in south america. *The Botanical Review*, v. 77, n. 4, p. 607-646, 2011. Doi: 10.1007/s12229-011-9088-6
- Bezerra, V. S. (2012). *Considerações sobre a palmeira Murumuruzeiro (Astrocaryum murumuru Mart.)* (Comunicado Técnico 130). Embrapa Amapá. <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/84961/1/AP-2012-Comunicado-tecnico-130-Murumuru.pdf>



- Bezerra, Valeria Saldanha. O Inajá (*Maximiliana maripa* (Aubl.) Drude) como fonte alimentar e oleaginosa. Embrapa Amapá-Comunicado Técnico (INFOTECA-E), 2011.
- Binoti, D. H.; Binoti, M. L. D. S.; Leite, H. G.; Silva, A. Redução dos custos em inventário de povoamentos equiâneos utilizando redes neurais artificiais. *Agrária - Revista Brasileira de Ciências Agrárias*, v. 8, p. 125- 129, 2013. Doi: 10.5039/agraria.v8i1a2209
- Binoti, M. L. M. S. Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto. 2010. 54 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa - MG, 2010.
- Bovi, M. L. A; Castro, A. Assaí (*Euterpe oleracea*, *Palmae*). In: Clay, J. W.; Clement, C. R (Org.). *Selected species and strategies to enhance income generation from Amazonian forests*. Rome: FAO, 1993. p.58-67.
- Braga, J. R. G.; Peripato, V.; Dalagnol, R.; Ferreira, M. P.; Tarabalka, Y.; Aragão, L. E. O. C.; Velho, H. F. C.; Shiguemori, E. H.; Wagner, F. H. Tree Crown Delineation Algorithm Based on a Convolutional Neural Network. *Remote Sensing*, v. 12, n. 8, p. 1288, 2020. Doi: doi:10.3390/rs12081288
- Braga-Neto, U. M., & Dougherty, E. R. (2004). Is cross-validation better than resubstitution for small-sample microarray classification? *Bioinformatics*, 20(3), 353–358.
- Carion, N., Massa, F., Synnaeve, G., Usunier, N., Kirillov, A., & Zagoruyko, S. (2020, August). End-to-end object detection with transformers. In *European conference on computer vision* (pp. 213-229). Cham: Springer International Publishing.
- Carneiro, T.; Da Nóbrega, R. V. M.; Nepomuceno, T.; Bian, G. B.; De Albuquerque, V. H. C.; Reboucas Filho, P. P. Performance analysis of google colab as a tool for accelerating deep learning applications. *IEEE Access*, v. 6, p. 61677-61685, 2018. Doi: 10.1109/ACCESS.2018.2874767
- Casapia, X. T., Cardenas-Vigo, R., Marcos, D., Gamarra, E. F., Bartholomeus, H., Coronado, E. N. H., ... Baker, T. R. (2025). Effective integration of drone technology for mapping and managing palm species in the Peruvian Amazon. *Nature Communications*, 16(1), 1–12. <https://doi.org/10.1038/s41467-025-58358-5>
- Casemiro, G. H. M.; Pinto, H. B. Composição e processamento de imagens aéreas de alta-resolução obtidas com drone. 2014. 80 f. Trabalho de Conclusão de Curso

- (Engenharia Eletrônica) – Faculdade UnB Gama (FGA), Universidade de Brasília (UnB), Brasília, 2014.
- Castro, W., et al. (2021). *Canopy palm cover across the Brazilian Amazon forests mapped with airborne LiDAR data and deep learning. Remote Sensing in Ecology and Conservation*, 7(3), 264–275.
- Costa, J.R. da; Van Leeuwen, J.; Costa, J. A. Tucumã-do-Amazonas, *Astrocaryum tucuma* Martius. In: Shanley, P, O.; Madina, G. (Ed.). *Frutíferas e plantas úteis na vida amazônica* Belém: CIFOR, Imazon, 2005. 215-222.
- Cui, K., Tang, W., Zhu, R., Wang, M., Larsen, G. D., Pauca, V. P., Alqahtani, S., Yang, F., Segurado, D., Fine, P., Karubian, J., Chan, R. H., Plemmons, R. J., Morel, J.-M., & Silman, M. R. (2024). Real-Time Localization and Bimodal Point Pattern Analysis of Palms Using UAV Imagery. *arXiv.Org*. <https://doi.org/10.48550/arXiv.2410.11124>
- Da Silva Sousa, Alice Neri et al. Charcoal produced from *Attalea tessmannii* Burret. fruit wastes. *SCIENTIA FORESTALIS*, v. 50, 2022.
- Do Nascimento, Janice Ferreira et al. Parâmetros Biométricos dos Cachos, Frutos e Sementes da Palmeira Murmururu (*Astrocaryum ulei* Burret.) encontrada na Região de Porto Acre, Acre. *Revista Brasileira de Biociências*, v. 5, n. S1, p. 90-92, 2007.
- Dos Santos, A. M.; Mitja, D.; Delaître, E.; Demagistri, L.; De Souza Miranda, I.; Libourel, T.; Petit, M. Estimating babassu palm density using automatic palm tree detection with very high spatial resolution satellite images. *Journal of environmental management*, v. 193, p. 40-51, 2017. Doi: 10.1016/j.jenvman.2017.02.004
- Duarte, A. F. Variabilidade e tendência das chuvas em Rio Branco, Acre, Brasil. *Revista Brasileira de Meteorologia*, v. 20, n. 1, p. 37-42, 2005.
- Duarte, O. R. Aspecto do estado da arte da produção e pesquisa em Inajá. In: CONGRESSO BRASILEIRO DE PLANTAS OLEAGINOSAS, ÓLEOS, GORDURAS E BIODIESEL, 5.; CLÍNICA TECNOLÓGICA EM BIODIESEL, 2., 2008, Lavras. Anais... UFLA, 2008.
- Duncanson, L., et al. (2022). Aboveground biomass density models across forested ecosystems. *Nature Climate Change*, 12, 78–85. <https://doi.org/10.1038/s41558-021-01288-6>
- Efron, B., & Tibshirani, R. J. (1993). *An Introduction to the Bootstrap*. Chapman & Hall.

- Eiserhardt, W. L.; Svenning, J. C.; Kissling, W. D.; Balslev, H. Geographical ecology of the palms (Arecaceae): determinants of diversity and distributions across spatial scales. *Annals of Botany*, v. 108, n. 8, p. 1391-1416, 2011. Doi: 10.1093/aob/mcr146
- IBGE (Instituto Brasileiro de Geografia e Estatística). Potencial Florestal do Estado do Acre (Relatório Técnico). Rio de Janeiro: IBGE, 2005. Disponível em: <<https://biblioteca.ibge.gov.br/visualizacao/livros/liv95899.pdf>>. Acesso: 01 nov. 2020.
- Elith, J., & Leathwick, J. R. (2009). Species Distribution Models: Ecological explanation and prediction across space and time. *Annual Review of Ecology, Evolution, and Systematics*, 40, 677–697.
- EMBRAPA. Centro Nacional de Pesquisa de Solos. (2006). Sistema Brasileiro de Classificação de Solos (2ª ed.). Rio de Janeiro: Embrapa Solos. 306 p. ISBN 85-85864-19-2.
- Ene, L. T.; Næsset, E.; Gobakken, T.; Bollandsås, O. M.; Maurya, E. W.; Zahabu, E. Large-scale estimation of change in aboveground biomass in miombo woodlands using airborne laser scanning and national forest inventory data. *Remote Sensing of Environment*, v. 188, p. 106-117, 2017. Doi: 10.1016/j.rse.2016.10.046
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115–118.
- Euler, A. M. C., Aubertin, C., & Cialdella, N. (2023). A sociobiodiversidade amazônica em busca de mercados internacionais. *Estudos de Sociologia*, e023013–e023013. <https://doi.org/10.52780/res.v28iesp.2.18868>
- European Centre for Medium-Range Weather Forecasts. (2025). *ECMWF Reanalysis v5*. ECMWF. <https://www.ecmwf.int/en/forecasts/dataset/ecmwf-reanalysis-v5>
- Everingham, M., Gool, L. V., Williams, C. K. I., Winn, J., & Zisserman, A. (2010). *The Pascal Visual Object Classes (VOC) Challenge*. *International Journal of Computer Vision*, 88(2), 303–338.
- Farr, T. G., et al. (2007). The Shuttle Radar Topography Mission. *Reviews of Geophysics*, 45(2). <https://doi.org/10.1029/2005RG000183>
- Farr, T.G., Rosen, P.A., Caro, E., Crippen, R., Duren, R., Hensley, S., Kobrick, M., Paller, M., Rodriguez, E., Roth, L., Seal, D., Shaffer, S., Shimada, J., Umland, J., Werner,

- M., Oskin, M., Burbank, D. e Alsdorf, D.E., 2007, The shuttle radar topography mission: Reviews of Geophysics, v. 45, no. 2, RG2004, at <https://doi.org/10.1029/2005RG000183>.
- Ferreira, M. P., Almeida, D. R. A. de, Papa, D. de A., Minervino, J. B. S., Veras, H. F. P., Formighieri, A., Santos, C. A. N., Ferreira, M. A. D., Figueiredo, E. O., & Ferreira, E. J. L. (2020). Individual tree detection and species classification of Amazonian palms using UAV images and deep learning. *Forest Ecology and Management*, 475, 118397. <https://doi.org/10.1016/j.foreco.2020.118397>
- Ferreira, M. P., Almeida, D. R. A. de, Papa, D. de A., Minervino, J. B. S., Veras, H. F. P., Formighieri, A., Santos, C. A. N., Ferreira, M. A. D., Figueiredo, E. O., & Ferreira, E. J. L. (2020). Individual tree detection and species classification of Amazonian palms using UAV images and deep learning. *Forest Ecology and Management*, 475, 118397. <https://doi.org/10.1016/j.foreco.2020.118397>
- Ferreira, M. P.; Almeida, D. R. A.; Almeida Papa, D.; Minervino, J. B. S.; Veras, H. F. P.; Formighieri, A.; Santos, C. A. N.; Ferreira, M. A. D.; Figueiredo, E. O.; FERREIRA, E. J. L.. Individual tree detection and species classification of Amazonian palms using UAV images and deep learning. *Forest Ecology and Management*, v. 475, p. 118397, 2020. DOI:10.1016/j.foreco.2020.118397.
- Figueiredo, E. O. Modelagem biométrica para arvores individuais a partir do Lidar em área de manejo de precisão em florestas tropicais na Amazônia Ocidental. 2014. 86 f. Tese (Doutorado em Ciências de Florestas Tropicais) – Programa de Pós-Graduação em Ciências de Florestas Tropicais, Instituto Nacional de Pesquisas da Amazônia (INPA), Manaus, 2014.
- Figueiredo, E. O., Melo Junior, A., Oliveira, L. C., Oliveira, M. V. N., Figueiredo, S. M. M., Silva, E. F., Papa, D. A., Santos, E. K. M., Guillen, M. G., Verás, H. F. P., Gonçalves, R. J. F., & Duarte, A. N. F. (2020). Manejo florestal 4.0: Passos para emprego de aeronaves remotamente pilotadas (drones) no planejamento florestal em nativas (Doc. 169). Embrapa Acre.
- Figueiredo, E. O., Santos, E. K. M. dos, Karasinski, M. A., Santos, C. A. N., Figueiredo, S. M. de M., & Verás, H. F. P. (2025). *Calendário fenológico para o reconhecimento de espécies florestais por meio de ortofotos na Amazônia Ocidental*. Anais do XXI Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 317920. Instituto Nacional de Pesquisas Espaciais (INPE). <https://proceedings.science/p/197858?lang=pt-br>

- Fontes, J. C.; Pozzetti, V. C. O Uso dos Veículos não Tripulados no Monitoramento Ambiental na Amazônia. *Revista de Direito e Sustentabilidade*, v. 2, n. 2, p. 149-164, 2016.
- Freitas, J. S., Mathis, A., Filho, M. C., Homma, A. K., & Silva, D. C. (2017). RESERVAS EXTRATIVISTAS NA AMAZÔNIA: MODELO CONSERVAÇÃO AMBIENTAL E DESENVOLVIMENTO SOCIAL? *GEOgraphia*, 19(40), 150. <https://doi.org/10.22409/geographia2017.v19i40.a13806>
- Fukushima, K. (1980). Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*, 36(4), 193–202.
- Funk, C., et al. (2015). The climate hazards infrared precipitation with stations—A new environmental record for monitoring extremes. *Scientific Data*, 2, 150066. <https://doi.org/10.1038/sdata.2015.66>
- Funk, C., P. Peterson, S. Peterson, S. Shukla F. Davenport, J. Michaelson, K. R. Knapp, M. Landsfeld, G. Husak, em L. Harrison, J. Rowland, M. Budde, A. Meiburg, T. Dinku, D. Pedreros e N. Mata, 2019: Um Registro de Dados Climáticos Tmax de Alta Resolução 1983-2016 Baseado em Temperaturas e Estações Infravermelhas pelo Risco Climático Centro. *J. Clima*, 32, 5639-5658. doi: 10.1175/JCLI-D-18-0698.1
- Galo, M. L. B. T. Caracterização Ambiental do Parque Estadual Morro do Diabo através de dados e técnicas de Sensoriamento Remoto: Abordagens utilizando redes neurais artificiais. 2000. 205 f. Tese (Doutorado em Ciências da Engenharia Ambiental) – Escola de Engenharia de São Carlos (EESC), Universidade de São Paulo (USP), São Carlos, 2000.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Grupo BBF. Sobre o Grupo BBF. Disponível em: <https://www.grupobbff.com.br/sobre-a-bbf/>. Acesso em: 31 maio 2025.
- Hajjaji, Y., Boulila, W., Farah, I. R., & Koubaa, A. (2025). Enhancing palm precision agriculture: An approach based on deep learning and UAVs for efficient palm tree detection. *Ecological Informatics*, 85, 102952. <https://doi.org/10.1016/j.ecoinf.2024.102952>



- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778.
- Henderson, A. (2000). *Balanço das palmeiras da Amazônia*. New York Botanical Garden Press.
- Henderson, A., Galeano, G., & Bernal, R. (1995). *Field Guide to the Palms of the Americas*. Princeton University Press
- Henderson, A.; Galeano, G. e Bernal, R. 1995. Field guide to the palms of the Americas. Pinceton University Press, New Jersey. 363p.
- Homma, A. K. O. (1992). The dynamics of extraction in Amazonia: a historical perspective. *Advances in Economic Botany*, 23-31.
- Homma, A. K. O. (2021). Amazônia: Manter a floresta em pé ou plantar? *Revista de Economia e Agronegócio*, 18(3), 1–17. <https://doi.org/10.25070/rea.v18i3.11134>
- Huete, A. R., Didan, K., Shimabukuro, Y. E., Ratana, P., Saleska, S. R., Hutyrá, L. R., Yang, W., Nemani, R. R., & Myneni, R. (2006). Amazon rainforests green-up with sunlight in dry season. *Geophysical Research Letters*, 33(6). <https://doi.org/10.1029/2005GL025583>
- IBGE. (2023). Mapa Digital de Solos do Brasil – Escala 1:250.000. Instituto Brasileiro de Geografia e Estatística. <https://www.ibge.gov.br>
- Instituto Nacional de Meteorologia-IMNET. (2019). *Banco de dados meteorológicos para ensino e pesquisa*. <https://bdmep.inmet.gov.br/>
- Itakura, K.; Hosoi, F. Automatic tree detection from three-dimensional images reconstructed from 360 spherical camera using YOLO v2. *Remote Sensing*, v. 12, n. 6, p. 988, 2020. Doi: 10.3390/rs12060988
- JAXA. (2018). ALOS PALSAR Radiometric Terrain Correction (RTC) data. Japan Aerospace Exploration Agency. <https://www.eorc.jaxa.jp/ALOS>
- Jintasuttisak, T.; Edirisinghe, E.; Elbattay, A. Deep neural network based date palm tree detection in drone imagery. *Computers and Electronics in Agriculture*, v. 192, p. 106560, 2022.

- Jirka, S., McDonald, A. J., Johnson, M. S., Feldpausch, T. R., Couto, E. G., & Riha, S. J. (n.d.). Relationships between soil hydrology and forest structure and composition in the southern Brazilian Amazon. *Journal of Vegetation Science*, 18(2), 183–194. <https://doi.org/10.1111/j.1654-1103.2007.tb02529.x>
- Kahn, F., & de Granville, J. J. (1992). *Palms in forest ecosystems of Amazonia*. Springer.
- Kahn, F., & De Granville, J. J. (2012). Palms in forest ecosystems of Amazonia (Vol. 95). *Springer Science & Business Media*.
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70–90.
- Karasinski, M. A., Leite, R. de S., Guaraná, E. C., Figueiredo, E. O., Broadbent, E. N., Silva, C. A., Santos, E. K. M. dos, Sanquetta, C. R., & Corte, A. P. D. (2025). Automated Detection of *Araucaria angustifolia* (Bertol.) Kuntze in Urban Areas Using Google Earth Images and YOLOv7x. *Remote Sensing*, 17(5). <https://doi.org/10.3390/rs17050809>
- Karasinski, M.A. Utilização de redes neurais convolucionais e imagens obtidas por RPA para o mapeamento de palmeiras na Amazônia Ocidental. (Dissertação) – Programa de Pós-Graduação em Ciências Florestais, Irati, PA, 2021.
- Karubian, J., Browne, L., Cabrera, D., Chambers, M., & Olivo, J. (2016). Relative influence of relatedness, conspecific density and microhabitat on seedling survival and growth of an animal-dispersed Neotropical palm, *Oenocarpus bataua*. *Botanical Journal of the Linnean Society*, 182(2), 425–438. <https://doi.org/10.1111/boj.12442>
- Kingo Oyama Homma, A. (2021). AMAZÔNIA: VENDA DE SERVIÇOS AMBIENTAIS OU DE ATIVIDADES PRODUTIVAS? *Terceira Margem Amazônia*, 6(16), 23–34. <https://doi.org/10.36882/2525-4812.2021v6i16.ed.esp.p23-34>
- Kissling, W. D.; Balslev, H.; Baker, W. J.; Dransfield, J.; Göldel, B.; Lim, J. Y.; Onstein, R. E.; Svenning, J. C. PalmTraits 1.0, a species-level functional trait database of palms worldwide. *Scientific Data*, v. 6, n. 178, 2019. Doi: 10.1038/s41597-019-0189-0
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. In *Advances in Neural Information Processing Systems*, 25.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-Based Learning Applied to Document Recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.

- Lee, S. S., Lim, L. G., Palaiahnakote, S., Cheong, J. X., Lock, S. S. M., & Ayub, M. N. B. (2024). Oil palm tree detection in UAV imagery using an enhanced RetinaNet. *Computers and Electronics in Agriculture*, 227, 109530. <https://doi.org/10.1016/j.compag.2024.109530>
- Lehner, B., Verdin, K., & Jarvis, A. (2008). New global hydrography derived from spaceborne elevation data. *Eos, Transactions American Geophysical Union*, 89(10), 93–94. <https://doi.org/10.1029/2008EO100001>
- Lescure, J. P. Algumas questões a respeito do extrativismo. In: Emperaire, L (Org.). *A floresta em jogo: o extrativismo na Amazônia Central*. São Paulo: UNESP, 2000.
- Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., & Zitnick, C. L. (2014). *Microsoft COCO: Common Objects in Context*. ECCV.
- Lippmann, R. P. An introduction to computing with neural nets. *IEEE ASSP Magazine*, v.4, n. 2, p. 4-22, 1987. Doi: 10.1109/MASSP.1987.1165576
- Litjens, G.; Kooi, T.; Bejnordi, B. E.; Setio, A. A. A.; Ciompi, F.; Ghafoorian, M.; Van Der Laak, J. A. W. M.; Van Ginneken, B.; Sánchez, C. I. A survey on deep learning in medical image analysis. *Medical image analysis*, v. 42, p. 60-88, 2017. Doi: 10.1016/j.media.2017.07.005
- Lorenzi, H., Souza, H. M. D., Costa, J. T. M., Cerqueira, L. S. C. D., & Ferreira, E. J. L. (2004). *Palmeiras brasileiras e exóticas cultivadas*.
- Loyola, R. D. (2014). *Fundamentos para a modelagem da distribuição de espécies*. Oficina de Textos.
- Mabetana, K. P. F., Noskoski, L. E. C., Pinto, N. G. M., Velho, J. P., Schardong, B. J. F., & Wachholz, G. A. (2024). Extrativismo de produtos florestais não madeireiros como mecanismo para a conservação da floresta na Amazônia. *Revista Políticas Públicas & Cidades*, 13(2), e1258. <https://doi.org/10.23900/2359-1552v13n2-305-2024>
- Melo, L. V. G. de, Ferreira, M. C. R., & Júnior, R. N. de C. (2024, April 10). Extração supercrítica e *Mauritia flexuosa*: potenciais aplicações na extração de componentes bioativos para o desenvolvimento de bioprodutos. *Anais Do IV Congresso Brasileiro de Biotecnologia On-Line*. <https://doi.org/10.51189/conbiotec2024/33233>
- Mendonça, C. C. de, & Ferreira, E. J. L. (2010). *Potencial da palmeira “jaci” (Attalea butyracea) para a produção de biodiesel em Rio Branco, Acre*. XIX Jornada de Iniciação Científica PIBIC INPA - CNPq/FAPEAM, Manaus.

- Meydenbauer, A.; Meyer, R. *Baukunst in historischen Fotografien*. Fotokinoverlag, 1985.
- Miranda, I. P. de A.; Rabelo, A.; Bueno, C. R.; Barbosa, E. M.; Ribeiro, M. N. S. *Frutos de palmeiras da Amazônia*. Manaus: INPA, 2001. 118 p.
- Miranda, I.; Libourel, T.; Petit, M. Estimating babassu palm density using automatic palm tree detection with very high spatial resolution satellite images. *Journal of environmental management*, v. 193, p. 40-51, 2017. Doi: 10.1016/j.jenvman.2017.02.004
- Moulatlet, G. M., Zuquim, G., Figueiredo, F. O. G., Lehtonen, S., Emilio, T., Ruokolainen, K., & Tuomisto, H. (2017). Using digital soil maps to infer edaphic affinities of plant species in Amazonia: Problems and prospects. *Ecology and Evolution*, 7(20), 8463–8477. <https://doi.org/10.1002/ece3.3242>
- Næsset, E. et al. Model-assisted regional forest biomass estimation using LiDAR and InSAR as auxiliary data: A case study from a boreal forest area. *Remote Sensing of Environment*, v. 115, n. 12, p. 3599-3614, 2011.
- Nair, V., & Hinton, G. E. (2010). Rectified Linear Units Improve Restricted Boltzmann Machines. In *Proceedings of the 27th International Conference on Machine Learning*.
- Nagaishi, T. Y. R., Silva, G. L., Oliveira, R. A., & Almeida, T. P. (2019). Use of the inajá stipe (*Attalea maripa* (Aubl.) Mart.) for the generation of bioenergy. *Revista Brasileira de Energias Renováveis*, 8(3). <http://dx.doi.org/10.5380/rber.v8i3.65664>
- Nevalainen, O. et al. Individual tree detection and classification with UAV-based photogrammetric point clouds and hyperspectral imaging. *Remote Sensing*, v. 9, n. 3, p. 185, 2017.
- Onstein, R. E.; Baker, W. J.; Couvreur, T. L.; Faurby, S.; Svenning, J. C.; e Kissling, W. D. Frugivory-related traits promote speciation of tropical palms. *Nature ecology & evolution*, v. 1, n. 12, p. 1903-1911, 2017. Doi: 10.1038/s41559-017-0348-7
- Pacheco-Palencia, Lisbeth A., Palo Hawken, and Stephen T. Talcott. "Phytochemical, antioxidant and pigment stability of açaí (*Euterpe oleracea* Mart.) as affected by clarification, ascorbic acid fortification and storage." *Food Research International* 40.5 (2007): 620-628.
- Pérez-Rodríguez, L. A.; Quintano, C.; Marcos, E.; Suarez-Seoane, S.; Calvo, L.; Fernández-Manso, A. Evaluation of Prescribed Fires from Unmanned Aerial Vehicles (UAVs)

- Imagery and Machine Learning Algorithms. *Remote Sensing*, v. 12, n. 8, p. 1295, 2020. Doi: 10.3390/rs12081295
- Pesce, C. Oleaginosas da Amazônia. Belém: Museu Paraense Emílio Goeldi, Núcleo de Estudo Agrários e Desenvolvimento Rural, 2009.
- Pettorelli, N., et al. (2014). Satellite remote sensing for applied ecologists: Opportunities and challenges. *Journal of Applied Ecology*, 51(4), 839–848.
- Phillips, S. J., Anderson, R. P., & Schapire, R. E. (2006). Maximum entropy modeling of species geographic distributions. *Ecological Modelling*, 190(3-4), 231–259.
- Powers, D. M. W. (2011). Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation. *Journal of Machine Learning Technologies*, 2(1), 37–63.
- Puttemans, S.; Van Beeck, K.; Goedemé, T. Comparing boosted cascades to deep learning architectures for fast and robust coconut tree detection in aerial images. In: Imai, F.; Tremeau, A.; Braz, J. (Org.). *Proceedings of the 13th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications - (Volume 5)*, in Funchal, Madeira, Portugal. 2018. p. 230-241. Doi: 10.5220/0006571902300241
- Redmon, J.; Divvala, S.; Girshick, R.; e Farhadi, A. You only look once: Unified, real-time object detection. *arXiv:1506.02640v5*, 2016.
- Redmon, J.; Farhadi, A. YoloV3: An incremental improvement. *arXiv preprint arXiv:1804.02767*, 2018.
- Rego, J. F. Amazônia: do extrativismo ao neoextrativismo. *Ciência Hoje*, v. 25, n. 147, p. 62-65, 1999.
- Resende, L. M., Franca, A. S., & Oliveira, L. S. (2019). Buriti (*Mauritia flexuosa* L. f.) fruit by-products flours: Evaluation as source of dietary fibers and natural antioxidants. *Food Chemistry*, 270, 53–60. <https://doi.org/10.1016/j.foodchem.2018.07.079>
- Rex, F. E.; Silva, C. A.; Dalla Corte, A. P.; Klauberg, C.; Mohan, M.; Cardil, A.; Silva, V. S.; Almeida, D. R. A.; Garcia, M.; Broadbent, E. N.; Valbuena, R.; Stoddart, J.; Merrick, T.; Hudak, A. T. Comparison of Statistical Modelling Approaches for Estimating Tropical Forest Aboveground Biomass Stock and Reporting their Changes in Low-intensity Logging Areas using Multi-temporal LiDAR Data. *Remote Sensing*, v. 12, n. 9, p. 1498, 2020. Doi: 10.3390/rs12091498



- Ribeiro, M. T.; Singh, S.; & Guestrin, C. (2016). "Why Should I Trust You?": Explaining the Predictions of Any Classifier. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*.
- Rizzini, C. T. *Tratado de fitogeografia do Brasil: aspectos ecológicos, sociológicos e florísticos*. Rio de Janeiro: Âmbito Cultural Edições Ltda. 1997.
- Rocha, E. Potencial ecológico para o manejo de frutos de açazeiro (*Euterpe precatória* Mart.) em áreas extrativistas no Acre, Brasil. *Acta amazônica*, v. 34, n. 2, p. 237-250, Manaus, 2004.
- Sabour, S.; Frosst, N.; & Hinton, G. E. (2017). Dynamic Routing Between Capsules. In *Advances in Neural Information Processing Systems*, 30.
- Santos, S. S., Carvalho, R. B. F. de, Silva, F. M. de S. e, Lima, S. da S., e Nunes, L. C. C. (2023). BABAÇU: EXPLORANDO SUAS CARACTERÍSTICAS E POTENCIALIDADES. In *Biotechnologia e farmacologia: abordagens interdisciplinares na terapêutica com recursos naturais* (pp. 97–116). Atena Editora. <https://doi.org/10.22533/at.ed.6652311126>
- Shanley, P. (2012). *Fruit trees and useful plants in amazonian life*. Food & Agriculture Organization of the UN (FAO).
- Shanley, P.; Medina, G. *Frutíferas e plantas úteis na vida amazônica*. Belém: CIFOR, Amazon, 2005. 300 p.
- Shanley, P.; Serra M.; Medina, G. (Ed.) *Frutíferas e plantas úteis na vida amazônica*. Belém, PA: CIFOR: Embrapa Amazônia Oriental: IMAZON, 2010. 304p.
- Silva, A. J. B. da, Sevalho, E. de S., & Miranda, I. P. de A. (2021). Potencial das palmeiras nativas da Amazônia Brasileira para a bioeconomia: análise em rede da produção científica e tecnológica. *Ciência Florestal*, 31, 1020–1046. <https://doi.org/10.5902/1980509843595>
- Simonyan, K.; & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv preprint arXiv:1409.1556*.
- Tan, M.; & Le, Q. V. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. In *Proceedings of the 36th International Conference on Machine Learning (ICML)*.
- Soberón, J., & Peterson, A. T. (2005). Interpretation of models of fundamental ecological niches and species' distributional areas. *Biodiversity Informatics*, 2, 1–10.


- Sousa, J. W. de. (2020). Características climáticas do município de Rio Branco, Acre, período de 1990-2019. *Scientia Naturalis*, 2(2).
- Ter Steege, H.; Henkel, T. W.; Helal, N.; Marimon, B. S.; Marimon-Junior, B. H.; Huth, A.; Groeneveld, J.; Sabatier, D.; Souza Coelho, L.; Andrade Lima Filho, D.; et al. Rarity of monodominance in hyperdiverse Amazonian forests. *Scientific reports*, v. 9, n. 1, p. 1-15, 2019. Doi: 10.1038/s41598-019-50323-9
- Turner, W., et al. (2003). Remote sensing for biodiversity science and conservation. *Trends in Ecology & Evolution*, 18(6), 306–314.
- van Rijsbergen, C. J. (1979). *Information Retrieval* (2nd ed.). Butterworth-Heinemann.
- Vaswani, A.; Shazeer, N.; Parmar, N.; et al. (2017). Attention is All You Need. In *Advances in Neural Information Processing Systems*, 30.
- Veloso, H. P. Sistema fitogeográfico. In: IBGE (Ed.). *Manual técnico da vegetação brasileira*. Série Manuais Técnicos em Geociências, v.1. Brasília: IBGE, p.8-38. 1992.
- Venturieri, A.; Santos, J. R. Técnicas de Classificação de Imagens para Análise de Cobertura Vegetal. In: Assad, E. D.; Sano, E. E (Org.). *Sistema de Informação Geográfica: Aplicações na Agricultura*. Brasília: Embrapa – SPI/Embrapa- CPAC, 1998. p. 351-371.
- Veras, H. F. P., Cunha Neto, E. M., Figueiredo, E. O., Dalla Corte, A. P., & Sanquetta, C. R. (2023). Estimating tree volume based on crown mapping by UAV pictures in the Amazon Forest. *Scientific Electronic Archives*, 16(7). <https://doi.org/10.36560/16720231742>
- Veras, H. F. P., Cunha Neto, E. M., Figueiredo, E. O., Dalla Corte, A. P., & Sanquetta, C. R. (2023). Estimating tree volume based on crown mapping by UAV pictures in the Amazon Forest. *Scientific Electronic Archives*, 16(7). <https://doi.org/10.36560/16720231742>
- Verdin, A., C. Funk, P. Peterson, M. Landsfeld, C. Tuholske e Grace, K., em 2020: Desenvolvimento e validação do CHIRTS-diário quasi-global conjunto de dados diários de temperatura de alta resolução. *Dados Científicos*, 7(1), 303. [doi: 10.1038/s41597-020-00643-7](https://doi.org/10.1038/s41597-020-00643-7)
- Vormisto, J. Palms as rainforest resources: how evenly are they distributed in Peruvian Amazonia?. *Biodiversity & Conservation*, v. 11, n. 6, p. 1025-1045, 2002.

- Wagner, F. H., Dalagnol, R., Casapia, X. T., Streher, A. S., Phillips, O. L., Gloor, E., & Aragão, L. E. O. C. (2020). Regional Mapping and Spatial Distribution Analysis of Canopy Palms in an Amazon Forest Using Deep Learning and VHR Images. *Remote Sensing*, 12(14). <https://doi.org/10.3390/rs12142225>
- Wagner, F. H., Dalagnol, R., Tagle Casapia, X., Streher, A. S., Phillips, O. L., Gloor, E., & Aragão, L. E. O. C. (2020). Regional mapping and spatial distribution analysis of canopy palms in an Amazon forest using deep learning and VHR images. *Remote Sensing*, 12(14), 2225. <https://doi.org/10.3390/rs12142225>
- Wang, A., Chen, H., Liu, L., Chen, K., Lin, Z., Han, J., & Ding, G. (2024, May 23). *YOLOv10: Real-Time End-to-End Object Detection*. arXiv.Org. <https://arxiv.org/abs/2405.14458>
- Wibowo, A., Trilaksono, B. R., Hidayat, E. M. I., & Munir, R. (2023). Object detection in dense and mixed traffic for autonomous vehicles with modified yolo. *IEEE Access*, 11, 134866–134877. <https://doi.org/10.1109/access.2023.3335826>
- Williams, E., C. Funk, P. Peterson e C. Seios tuholske (2024). Alta resolução de observações e projeções sobre mudanças climáticas para a avaliação de extremos relacionados ao calor. *Dados Científicos*, 11(1), 261. [doi: 10.1038/s41597-024-03074-w](https://doi.org/10.1038/s41597-024-03074-w)
- Witten, I. H., Frank, E., & Hall, M. A. (2011). *Data Mining: Practical Machine Learning Tools and Techniques*. Morgan Kaufmann.
- Yamazaki D., D. Ikeshima, J. Sosa, P.D. Bates, G.H. Allen, T.M. Pavelsky. MERIT Hydro: um mapa hidrográfico global de alta resolução baseado nos conjuntos de dados de topografia mais recentes *Water Resources Research*, vol.55, pp.5053-5073, 2019, [doi:10.1029/2019WR024873](https://doi.org/10.1029/2019WR024873)
- Yamazaki, D., Ikeshima, D., Sosa, J., Bates, P. D., Allen, G. H., & Pavelsky, T. M. (2019). MERIT Hydro: A High-Resolution Global Hydrography Map Based on Latest Topography Dataset. *Water Resources Research*, 55(6), 5053–5073. <https://doi.org/10.1029/2019WR024873>
- Zhang, C., et al. (2021). Remote sensing-based species distribution modeling: Methods and applications. *Remote Sensing*, 13(15), 2956. <https://doi.org/10.3390/rs13152956>
- Zheng, J.; Fu, H.; Li, W.; Wu, W.; Yu, L.; Yuan, S.; Tao, W. Y. W.; Pang, T. K.; Kanniah, K. D. Growing status observation for oil palm trees using Unmanned Aerial Vehicle

- (UAV) images. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 173, p. 95-121, 2021. Doi: 10.1016/j.isprsjprs.2021.01.008
- Zheng, J.; Li, W.; Xia, M.; Dong, R.; Fu, H.; Yuan, S. Large-scale oil palm tree detection from high-resolution remote sensing images using faster-rcnn. In: *IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium*, Yokohama, 2019. Anais eletrônico... Yokohama: IEEE, p. 1422-1425. Doi: 10.1109/IGARSS.2019.8898360
- Zhou, B.; Khosla, A.; Lapedriza, A.; Oliva, A.; & Torralba, A. (2016). Learning Deep Features for Discriminative Localization. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Zhu, X. X.; Tuia, D.; Mou, L.; Xia, G. S.; Zhang, L.; Xu, F.; Fraundorfer, F. Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE Geoscience and Remote Sensing Magazine*, v. 5, n. 4, p. 8-36, 2017. Doi: 10.1109/MGRS.2017.2762307
- Zuffo, A. M., Silva, D. D. da, Zuffo, J. A. M., & Zuffo, M. M. (2016). Biometric characterization of fruits and seeds mirindiba (*Buchenavia tomentosa* Eichler) and inajá (*Attalea maripa* [Aubl.] Mart.) in southern Piauí, Brazil. *Revista de Ciências Agrárias*, 39(3), 331–340. <http://dx.doi.org/10.19084/rca15152>

## ANEXO 1

FIGURA 42 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE *Astrocaryum aculeatum* (aa14) NO ESTADO DO ACRE.




FONTE: o autor (2025).



## ANEXO 2


FIGURA 43 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE *attalea butyracea* (ab10) NO ESTADO DO ACRE.



FONTE: o autor (2025).

## ANEXO 3


FIGURA 44 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE *Attalea maripa* (am16) NO ESTADO DO ACRE.



FONTE: o autor (2025).

## ANEXO 4


FIGURA 45 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE *Attalea phalerata* (ap12) NO ESTADO DO ACRE.





## ANEXO 5


FIGURA 46 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE *Astrocaryum ulei* (au13) NO ESTADO DO ACRE.



FONTE: o autor (2025).

## ANEXO 6

FIGURA 47 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE *Euterpe precatoria* (ep01 E ep35) NO ESTADO DO ACRE.




FONTE: o autor (2025).



## ANEXO 7


FIGURA 48 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE *Mauritia flexuosa* (mf09) no ESTADO DO ACRE.



FONTE: o autor (2025).

## ANEXO 8


FIGURA 49 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE *Oenocarpus bataua* (ob19) no ESTADO DO ACRE.



FONTE: o autor (2025).

## ANEXO 9

FIGURA 50 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE *Socratea exorrhiza* (sc04) NO ESTADO DO ACRE.




FONTE: o autor (2025).



## ANEXO 10


FIGURA 51 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE *Attalea speciosa* (as48) NO ESTADO DE RONDÔNIA.



FONTE: o autor (2025).

## ANEXO 11

Figura 52 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE *Mauritiella armata* (ma79) NO ESTADO DE RONDÔNIA.




FONTE: o autor (2025).



## ANEXO 12


Figura 53 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE *Astrocaryum jauari* (aj82) NO ESTADO DE RORAIMA.



FONTE: o autor (2025).

## ANEXO 13

Figura 54 - DISTRIBUIÇÃO ESPACIAL DA DENSIDADE ESTIMADA DA ESPÉCIE *Oenocarpus bacaba* (ob70) NO ESTADO DE RORAIMA.



FONTE: o autor (2025)